


**Universidade do Minho**  
Escola de Engenharia

Getúlio Paulo Peixoto Igrejas

**Segmentação de Imagens Fetais  
com Potencial para Desenvolvimento  
de Ferramentas de Apoio ao Diagnóstico**

Julho de 2015



**Universidade do Minho**  
Escola de Engenharia

Getúlio Paulo Peixoto Igrejas

**Segmentação de Imagens Fetais  
com Potencial para Desenvolvimento  
de Ferramentas de Apoio ao Diagnóstico**

Tese de Doutoramento  
Programa Doutoral em Engenharia Electrónica  
e de Computadores

Trabalho efectuado sob a orientação do  
**Professor Doutor Carlos Alberto Caridade Monteiro e Couto**  
**Professor Doutor Paulo Alexandre Cardoso Salgado**

Julho de 2015



## DECLARAÇÃO DE INTEGRIDADE

Declaro ter atuado com integridade na elaboração da presente tese. Confirmo que em todo o trabalho conducente à sua elaboração não recorri à prática de plágio ou a qualquer forma de falsificação de resultados. Mais declaro que tomei conhecimento integral do Código de Conduta Ética da Universidade do Minho.

Universidade do Minho, 31 de Julho de 2015

Nome completo: Getúlio Paulo Peixoto Igrejas

Assinatura:



A meus Pais

Ao Gonçalo, à Beatriz e ao Francisco



## **AGRADECIMENTOS**

Ao Professor Doutor Carlos Alberto Caridade Monteiro e Couto pela orientação, acompanhamento e ajuda dispensada durante o longo período deste trabalho. Foi para mim uma enorme honra tê-lo como orientador.

Ao Professor Doutor Paulo Alexandre Cardoso Salgado pela orientação, pelas sugestões e ajuda prestadas na execução dos trabalhos e na redação deste documento.

Ao Dr. Matos Cruz pela disponibilização das imagens usadas neste trabalho e pela perspectiva médica que lhe conferiu.

À Joana pela leitura cuidada, pelas sugestões e ajuda a organizar este documento, pelo incentivo, apoio e paciência demonstrados durante o período deste trabalho.

Aos meus pais pelo incentivo contínuo.

Ao meu irmão, Gilberto, sua esposa Patrícia e seus filhos, Gonçalo, Beatriz e Francisco o incessante incentivo mas sobretudo o carinho com que me mimam.

A todos os meus amigos que de forma mais indireta me apoiaram e incentivaram neste trabalho.



# RESUMO

Durante uma gravidez é aconselhável a realização de 3 exames ecográficos. O primeiro, e reconhecido pelos especialistas como mais importante, é o do primeiro trimestre. Neste exame, realizado entre as 11 e as 14 semanas, é possível avaliar a idade gestacional, o desenvolvimento fetal e, mais importante, as anomalias fetais. Na avaliação das anomalias fetais incluem-se as cromossômicas, que são detetáveis a partir da observação da medida da Translucência da Nuca mas que deve ser cruzada com a medida da Distância Crânio-Caudal e a idade materna. As medidas são retiradas manualmente e os seus valores variam com a disponibilidade física e a motivação do operador, pelo que os resultados mostram variabilidade intra e inter-operador.

As imagens recolhidas pelos sistemas de aquisição baseados em ultrassons apresentam pouco detalhe, baixo contraste, baixa relação sinal/ruído e grande variabilidade morfológica que dificulta a tarefa de segmentação e, consequentemente, o desenvolvimento de sistemas de medição automáticos. Como tal, o seu tratamento exige a utilização de técnicas que reúnam características adequadas e que permitam o desenvolvimento de sistemas robustos.

Este trabalho trata a questão da extração automática da medida da Distância Crânio-Caudal (DCC) a partir das imagens de ultrassons habitualmente usadas para este fim. Para tal, propõe a utilização de técnicas de *Fuzzy Clustering*, de Contornos Ativos e de Aprendizagem Máquina, nomeadamente SVMs, para a segmentação das imagens com vista à identificação do corpo do feto. Estas abordagens potenciaram a formulação de novos modelos que permitem enfrentar as dificuldades inerentes ao tratamento deste tipo de imagens.

São também propostas metodologias automáticas de extração da medida DCC, sendo que algumas delas dependem dos processos de segmentação sugeridos. Os resultados obtidos para a medida da DCC apresentam um erro absoluto médio relativo dentro dos intervalos de variabilidade inter-operador referidos na literatura.

PALAVRAS-CHAVE: SEGMENTAÇÃO, FUZZY CLUSTERING, CONTORNOS ATIVOS, SVM, ECOGRAFIAS FETAIS, DISTÂNCIA CRÂNIO-CAUDAL





# ABSTRACT

During pregnancy it is advisable to conduct 3 ultrasound examinations. The first and most important is performed in the first trimester. In this exam, done between the 11<sup>th</sup> and 14<sup>th</sup> week, the gestational age, the fetal development and, most importantly, the fetal abnormalities can be assessed. The assessment of fetal anomalies include chromosomal, which are detectable from observation measuring the nuchal translucency size. However it should be crossed with a measure of the crown-rump length and the maternal age. These measures are manually performed and their values vary with the physical availability and motivation of the operator, so the results show intra and inter-operator variability.

The images collected by acquisition systems based on ultrasounds have little detail, low contrast, low signal/noise ratio and great morphological variability which difficult the segmentation task and the development of automatic measuring systems. Because of these reasons, ultrasound image processing requires the use of techniques that meet appropriate characteristics and that enable the development of robust systems.

This work treats the subject of automatic extraction of the crown-rump length from ultrasound images commonly used for this purpose. It uses Fuzzy Clustering, Active Contours and Machine Learning techniques for the segmentation of images in order to identify the fetal body. These approaches promoted the development of new models that allow face the inherent difficulties in treating this type of images.

Methods for the crown-rump length automatic measurement are also proposed, some of which depend on the suggested segmentation methods. The results obtained for the crown-rump length presented a relative mean absolute error within inter-operator variability ranges reported in the literature.

KEYWORDS: SEGMENTATION, FUZZY CLUSTERING, ACTIVE CONTOURS, SVM, ULTRASOUND FETAL IMAGES, CROWN-RUMP LENGTH



# ÍNDICE

Agradecimentos .....	v
Resumo .....	ix
Abstract .....	xi
Índice .....	xiii
Lista de Abreviaturas, Siglas e Acrónimos .....	xxv
Lista de Figuras .....	xvii
Lista de Tabelas .....	xxiii
Introdução Geral e Objetivos .....	xxv
Organização do Documento .....	5
1. Exame Fetal .....	7
1.1 Introdução .....	7
1.2 Ultrassons .....	9
1.3 Formação da imagem .....	17
1.4 Medidas .....	22
1.5 Distância Crânio-Caudal .....	23
1.6 Diâmetro Biparietal .....	26
1.7 Translucência da Nuca .....	26
1.8 Conclusão .....	27
2. Medidas em Ecografias Fetais .....	29
2.1 Estado da Arte .....	29
3. Técnicas de <i>Fuzzy Clustering</i> .....	41
3.1 Introdução .....	41
3.2 <i>Fuzzy C-Means</i> .....	41
3.3 Limite de Decisão Baseado na Vizinhança .....	43
3.4 <i>Fuzzy C-means</i> com Informação Espacial .....	44
3.4.1 FCMS <sub>1</sub> .....	44
3.4.2 FCMS <sub>2</sub> e FCMS <sub>2m</sub> .....	45
3.4.3 FCMS <sub>3</sub> .....	47
3.4.4 GKFCM .....	49

3.5	Validação da Segmentação .....	50
3.6	Conclusão .....	53
4.	Contornos Ativos e <i>Level Sets</i> .....	55
4.1	Introdução .....	55
4.2	Contornos Ativos.....	56
4.3	<i>Level Sets</i> .....	57
4.4	Contornos Ativos sem Gradiente – Chan - Vese .....	61
4.5	Conclusão .....	63
5.	Segmentação por Aprendizagem.....	65
5.1	Introdução .....	65
5.2	Aprendizagem Estatística .....	66
5.3	Dimensão Vapnik-Chervonenkis (VC) .....	68
5.4	Minimização do Risco Estrutural .....	70
5.5	Classificação com Vetores de Suporte .....	71
5.5.1	Separação Linear.....	71
5.5.2	Separação Linear em Dados Não Separáveis Linearmente.....	75
5.5.3	Separação Não-Linear .....	78
5.6	<i>Kernels</i> .....	79
5.6.1	Polinomial .....	79
5.6.2	Função Gaussiana de Base Radial.....	80
5.6.3	Função Exponencial de Base Radial .....	80
5.6.4	Perceptron Multicamada .....	80
5.6.5	Série de Fourier .....	81
5.6.6	Kernel Aditivo .....	81
5.6.7	Produto Tensorial.....	81
5.7	Seleção do <i>Kernel</i> .....	81
5.8	Sugestão de um Método de Segmentação das Imagens Fetais .....	82
5.8.1	Análise de Componentes Principais.....	83
5.8.2	<i>Whitening</i> dos Dados .....	85
5.9	Conclusão .....	86

6. Análise e Discussão de Resultados.....	87
6.1 Introdução .....	87
6.2 <i>Fuzzy Clustering</i> .....	87
6.2.1 FCM .....	88
6.2.2 FCMV .....	89
6.2.3 FCMS <sub>1</sub> .....	91
6.2.4 FCMS <sub>2</sub> e FCMS <sub>2m</sub> .....	93
6.2.5 FCMS <sub>3</sub> .....	95
6.2.6 GKFCM.....	97
6.3 Validação dos Métodos de <i>Fuzzy Clustering</i> .....	98
6.4 Contornos Ativos.....	101
6.5 Segmentação de Imagens Fetais com Recurso a um Classificador SVM .....	111
6.5.1 Segmentação Baseada no Contorno Fetal .....	111
6.5.2 Segmentação Baseada no Contorno e Corpo Fetal .....	114
6.5.3 Desempenho do Classificador em Função do Número de Componentes Principais, da Máscara e do Peso do Erro de Classificação da SVM .....	117
6.6 Extração da Distância Crânio-Caudal .....	119
6.6.1 Extração a Partir das Imagens Segmentadas – Método 1 .....	119
6.6.2 Extração a Partir das Imagens Segmentadas – Método 2 .....	120
6.6.3 Extração a Partir das Imagens Segmentadas – Método 2.....	122
6.6.4 Avaliação dos Resultados das Medições .....	123
6.6.5 Extração da Medida DCC com Recurso a Classificador SVM.....	124
6.7 Conclusão .....	126
Conclusões Gerais e Trabalho Futuro .....	129
Bibliografia .....	135
Anexo A – Prova FCM .....	143
Anexo B – Discretização da implementação do método chan-vese .....	147
Anexo C – Condições de Mercer.....	149



# LISTA DE FIGURAS

Figura 1.1 – Visualização da energia da onda sonora como um modelo mecânico de compressão-descompressão de uma mola. As zonas escuras correspondem a amplitudes elevadas de maior energia (compressão) e as zonas a branco a zonas de baixa energia (descompressão) (retirado de (Bushberg, Seibert, Leidholdt, & Boone, 2011)).	9
Figura 1.2 – Atenuação normalizada da propagação da onda num meio homogêneo como função da distância.	10
Figura 1.3 – Reflexão e refração de uma onda sonora numa interface (adaptada de (Suri <i>et al.</i> , 2002)).	12
Figura 1.4 – Espalhamento provocado por estruturas cuja dimensão é menor que o comprimento de onda e pela irregularidade da superfície entre dois tecidos (interface) (adaptado de (Bushberg <i>et al.</i> , 2011)).	13
Figura 1.5 – Componentes axial, lateral e vertical para um <i>array</i> de ultrassons (retirada de (Bushberg <i>et al.</i> , 2011)).	14
Figura 1.6 – Dependência da resolução axial com a distância entre interfaces e a frequência do pulso emitido (retirada de (Bushberg <i>et al.</i> , 2011)).	14
Figura 1.7 – Efeito da variação da resolução lateral com a profundidade na construção da imagem (adaptado de (Bushberg <i>et al.</i> , 2011)).	15
Figura 1.8 – Modificação do ponto focal por variação da temporização de excitação dos transdutores do array (retirado de (Bushberg <i>et al.</i> , 2011)).	16
Figura 1.9 – Variação da resolução vertical para múltiplos pontos focais com múltiplos transdutores (retirado de (Bushberg <i>et al.</i> , 2011)).	16
Figura 1.10 – Energia propagada em direções que não a principal sob a forma de lobos laterais (adaptado de (Bushberg <i>et al.</i> , 2011)).	16
Figura 1.11 – Fotografia de um equipamento típico para aquisição de imagens por ultrassons.	17
Figura 1.12 – Princípio de funcionamento de um sistema de ultrassons pulso-eco (adaptado de (Suri <i>et al.</i> , 2002)).	18
Figura 1.13 – Princípio de funcionamento do modo A (adaptado de (Suri <i>et al.</i> , 2002)).	19
Figura 1.14 – Princípio de funcionamento do modo B (adaptado de (Suri <i>et al.</i> , 2002)).	19
Figura 1.15 – Princípio de funcionamento do modo M (adaptado de (Suri <i>et al.</i> , 2002)).	19
Figura 1.16 – Funcionamento típico de uma sonda rotativa.	20
Figura 1.17 – Arranjo dos transdutores num array linear e num array curvilíneo. As setas indicam o sentido da excitação dos transdutores (adaptado de (Bushberg <i>et al.</i> , 2011)).	20
Figura 1.18 – Princípio de funcionamento de um <i>phased-array</i> (adaptado de (Bushberg <i>et al.</i> , 2011)).	21
Figura 1.19 – Imagem fetal típica de um sistema <i>Real-Time B-scan</i> .	21
Figura 1.20 – Idade Gestacional, em semanas, em função da DCC para as Equações (1.8) e (1.9).	24

Figura 1.21 – Exemplo de uma imagem fetal correta para medição da DCC com a marcação da medida (imagem gentilmente cedida pelo Dr. Matos Cruz).....	24
Figura 1.22 – Exemplos de <i>calipers</i> colocados de forma correta e incorreta para a realização de uma medição. ....	25
Figura 1.23 – Exemplo de uma imagem para medição do DBP (imagem gentilmente cedida pelo Dr. Matos Cruz). ....	26
Figura 1.24 – Imagem usada para a medição da TN (imagem gentilmente cedida pelo Dr. Matos Cruz).....	27
Figura 4.1 – A curva vista como o <i>Level Set</i> zero de uma superfície (FLS).....	58
Figura 5.1 – Erros de modelação vistos nos espaços de soluções (adaptado de (Gunn, 1998)). ....	67
Figura 5.2 – Separação, por retas orientadas, de 3 pontos em $\mathbb{R}^2$ . Os pontos a cheio representam uma classe e a vazio a outra (adaptada de (Borges, 1998)). ....	69
Figura 5.3 – Exemplo da dimensão VC para 4 pontos em $\mathbb{R}^2$ . Nem todos os classificadores usados realizam a separação de todos os pontos, independentemente da distribuição dos mesmos pelas duas classes. Para a distribuição das classes definida e para as duas funções separadoras selecionadas apenas é possível separar corretamente 3 dos 4 pontos. ....	70
Figura 5.4 – Subespaços de hipóteses ordenados pela dimensão VC.....	70
Figura 5.5 – Hiperplanos de separação possíveis para padrões linearmente separáveis em $\mathbb{R}^2$ .....	72
Figura 5.6 – Hiperplano ótimo que maximiza a distância entre as classes. Os pontos mais próximos do hiperplano são designados por vetores de suporte (representados a cheio). ....	72
Figura 5.7 – Hiperplano de separação linear ótimo. Os padrões vetores de suporte estão assinalados com um círculo envolvente. ....	73
Figura 5.8 – Exemplo de uma distribuição dos padrões de treino em que não é possível realizar a separação linear das classes. ....	76
Figura 5.9 – Dados com características que não permitem uma separação linear.....	78
Figura 5.10 – Excerto da máscara radial híbrida usada para a construção do espaço de características. Pc representa o pixel central e P1-P5 uma parte dos pixéis para um dos raios usados na extração de características. ....	83
Figura 5.11 – Exemplo de uma distribuição com indicação dos vetores próprios que maximizam a variância. ..	84
Figura 5.12 – Representação dos dados anteriores no novo eixo definido pelas componentes principais depois de aplicada a PCA.....	84
Figura 5.13 – Resultado do <i>whitening</i> aplicado ao exemplo apresentado na subsecção 5.8.1.....	85
Figura 5.14 – Fases do processo de classificação implementado para segmentação das imagens fetais com recurso à SVM. ....	86
Figura 6.1 – Imagens selecionadas para avaliação do desempenho das metodologias de <i>Fuzzy Clustering</i> . ....	88
Figura 6.2 – Partições resultantes da aplicação do método FCM. O nível de intensidade representa o grau de pertença. ....	88
Figura 6.3 – Resultados da aplicação do método FCM definido para 2 <i>clusters</i> e $m=2$ . ....	89



Figura 6.4 – Resultado da segmentação baseada no FCMV com decisão baseada na vizinhança para janelas de 3x3 a 8x8 (imagem superior esquerda corresponde à janela 3x3 e a imagem inferior direita a 8x8. A dimensão aumenta da esquerda para a direita e de cima para baixo). .....	90
Figura 6.5 - Resultado da segmentação baseada no FCMV com decisão baseada na vizinhança para janelas de 3x3 a 8x8 (imagem superior esquerda corresponde à janela 3x3 e a imagem inferior direita a 8x8. A dimensão aumenta da esquerda para a direita e de cima para baixo). .....	90
Figura 6.6 – Resultado da segmentação baseada no FCMV com decisão baseada na vizinhança para janelas de 3x3 a 8x8 (imagem superior esquerda corresponde à janela 3x3 e a imagem inferior direita a 8x8. A dimensão aumenta da esquerda para a direita e de cima para baixo). .....	91
Figura 6.7 – Resultados da aplicação do método FCMS <sub>1</sub> para janelas 3x3 (cima) e de 20x20 (baixo), $p=q=1$ . ..	92
Figura 6.8 – Variação do resultado da segmentação com o aumento do peso da informação espacial. Da esquerda para a direita $q=2$ , $q=3$ e $q=4$ , respetivamente. ....	92
Figura 6.9 – Resultado da aplicação do método FCMS <sub>2</sub> com informação espacial para janelas 5x5 (cima) e 10x10 (baixo). $\alpha = 5$ . ....	93
Figura 6.10 – Resultados da aplicação do método FCMS <sub>2m</sub> para janelas 5x5 (cima) e 10x10 (baixo), $\alpha = 5$ . ....	94
Figura 6.11 – Resultado de FCMS <sub>2</sub> para janelas 5x5 e $\alpha = 3$ (cima) e $\alpha = 10$ (baixo). ....	94
Figura 6.12 – Resultado do método FCMS <sub>2m</sub> para janela 5x5 e $\alpha = 3$ (cima) e $\alpha = 10$ (baixo). ....	95
Figura 6.13 – Resultado da segmentação segundo o método FCMS <sub>3</sub> com $\lambda_s = 0.5$ , $\lambda_g = 3$ e janela 3x3 (cima) e 5x5 (baixo). ....	96
Figura 6.14 – Variação do resultado da segmentação com a variação do parâmetro $\lambda_g$ , ( $\lambda_s = 3$ e $\lambda_g = \{1, 3, 6\}$ , de cima para baixo). ....	96
Figura 6.15 – Variação do resultado da segmentação com a variação do parâmetro $\lambda_s$ , ( $\lambda_g = 0.5$ e $\lambda_s = \{1, 3, 6\}$ , de cima para baixo). ....	97
Figura 6.16 – Resultado da segmentação pelo método GKFCM com filtro de média e janela 5x5 .....	98
Figura 6.17 – Resultado da segmentação do GKFCM com filtro mediana e janela 5x5 .....	98
Figura 6.18 - Evolução do LS zero (curva a vermelho) a cada 30 iterações de execução. A imagem do topo à esquerda apresenta o LS inicial usado e a imagem inferior à direita o resultado após 150 iterações, com $\mu = 0.01 \times 255^2$ , $\lambda_1 = 1.0$ e $\lambda_2 = 1.0$ . $\lambda_1$ representa o peso atribuído à região interior do LS, $\lambda_2$ o peso atribuído à região exterior e $\mu$ o peso atribuído ao comprimento do LS zero. ....	102
Figura 6.19 - Evolução do LS zero (curva a vermelho) a cada 30 iterações de execução. A imagem do topo à esquerda apresenta o LS inicial usado e a imagem inferior à direita o resultado após 150 iterações, com $\mu = 0.01 \times 255^2$ , $\lambda_1 = 1.0$ e $\lambda_2 = 1.0$ . $\lambda_1$ representa o peso atribuído à região interior do LS, $\lambda_2$ o peso atribuído à região exterior e $\mu$ o peso atribuído ao comprimento do LS zero. ....	103
Figura 6.20 - Evolução do LS zero (curva a vermelho) a cada 30 iterações de execução. A imagem do topo à esquerda apresenta o LS inicial usado (obtido por aplicação do método GKFCM) e a imagem inferior à direita o resultado após 150 iterações, com $\mu = 0.01 \times 255^2$ , $\lambda_1 = 1.0$ e $\lambda_2 = 1.0$ . $\lambda_1$ representa o peso atribuído à região interior do LS, $\lambda_2$ o peso atribuído à região exterior e $\mu$ o peso atribuído ao comprimento do LS zero. ....	103

Figura 6.21 – Resultado da evolução do LS da Figura 6.18 após 1000 iterações. ....	104
Figura 6.22 - Evolução do LS zero (curva a vermelho) a cada 30 iterações de execução. A imagem do topo à esquerda apresenta o LS inicial usado e a imagem inferior à direita o resultado após 150 iterações, com $\mu = 0.01 \times 255^2$ , $\lambda_1 = 1.8$ e $\lambda_2 = 1.0$ . $\lambda_1$ representa o peso atribuído à região interior do LS, $\lambda_2$ o peso atribuído à região exterior e $\mu$ o peso atribuído ao comprimento do LS zero. ....	104
Figura 6.23 – Evolução do LS zero (curva a vermelho) a cada 30 iterações de execução. A imagem do topo à esquerda apresenta o LS inicial usado e a imagem inferior à direita o resultado após 150 iterações, com $\mu = 0.01 \times 255^2$ , $\lambda_1 = 1.8$ e $\lambda_2 = 1.0$ . $\lambda_1$ representa o peso atribuído à região interior do LS, $\lambda_2$ o peso atribuído à região exterior e $\mu$ o peso atribuído ao comprimento do LS zero. ....	105
Figura 6.24 - Evolução do LS zero (curva a vermelho) a cada 30 iterações de execução. A imagem do topo à esquerda apresenta o LS inicial usado (obtido por aplicação do método GKFCM) e a imagem inferior à direita o resultado após 150 iterações, com $\mu = 0.01 \times 255^2$ , $\lambda_1 = 1.8$ e $\lambda_2 = 1.0$ . $\lambda_1$ representa o peso atribuído à região interior do LS, $\lambda_2$ o peso atribuído à região exterior e $\mu$ o peso atribuído ao comprimento do LS zero. ....	105
Figura 6.25 – Resultado da evolução da curva para $\lambda_1 = 1.0$ , $\lambda_1 = 2.0$ e $\lambda_1 = 4.0$ (da esquerda para a direita) após convergência. As imagens superiores correspondem à utilização da função LS inicial definida pelo conjunto de círculos que abrangem a totalidade da imagem e as imagens inferiores à utilização do resultado do método GKFCM. ....	106
Figura 6.26 – Resultado da evolução do contorno para $\lambda_1 = 1.0$ , $\lambda_1 = 1.8$ e $\lambda_1 = 2.0$ (da esquerda para a direita). $\lambda_2 = 1.0$ . Cima: função inicial definida pelo conjunto de círculos; baixo: LS inicial resultado do GKFCM. ....	106
Figura 6.27 – Resultado da evolução do contorno para $\lambda_2 = 1.0$ , $\lambda_2 = 1.8$ e $\lambda_2 = 2.0$ (da esquerda para a direita). $\lambda_1 = 1.0$ . Cima: função inicial definida pelo conjunto de círculos; baixo: LS inicial resultado do GKFCM. ....	107
Figura 6.28 – Resultado da evolução do contorno para $\lambda_1 = 1.0$ , $\lambda_1 = 1.8$ e $\lambda_1 = 2.5$ (da esquerda para a direita). $\lambda_2 = 1.0$ . Cima: função inicial definida pelo conjunto de círculos; baixo: LS inicial resultado do GKFCM. ....	108
Figura 6.29 – Resultado da evolução do LS para $\mu = 0.001$ , $\mu = 0.01$ e $\mu = 0.02$ (da esquerda para a direita). $\lambda_1 = \lambda_2 = 1.0$ . Cima: LS inicial definido pelo conjunto de círculos; baixo: LS inicial resultado do GKFCM. ....	108
Figura 6.30 – Histograma de intensidades da Imagem 1, 2 e 3 da Figura 6.1, respetivamente. ....	109
Figura 6.31 – Resultado da evolução do LS inicial, definido pelos círculos, após 5000 iterações, para os pesos calculados a partir do histograma da imagem. Na primeira imagem foi usado para $\lambda_1 = 4.1$ e $\lambda_2 = 1.0$ . Na segunda imagem foi usado para $\lambda_1 = 1.0$ e $\lambda_2 = 1.5$ . Na terceira imagem foi usado para $\lambda_1 = 3.8$ e $\lambda_2 = 1.0$ . Foi usado o mesmo valor de $\mu$ em todas as simulações. ....	110
Figura 6.32 – Resultados da segmentação para algumas das imagens de treino. A imagem da esquerda corresponde à imagem original, a imagem central à anotação realizada manualmente e a da direita ao resultado da aplicação da SVM. ....	112
Figura 6.33 – Resultados da segmentação para imagens não treinadas. À esquerda a imagem original e à direita o resultado do classificador. ....	113

Figura 6.34 – Resultado da classificação da SVM sobre algumas das imagens de treino depois de treinada com as características extraídas da imagem reescalada para 40% do tamanho original com máscara de 24 raios, C=15 e usadas 25 componentes principais. À esquerda a imagem original, ao centro as imagens anotadas e à direita o resultado da segmentação. ....	115
Figura 6.35 - Resultado da classificação da SVM sobre algumas das imagens de teste depois de treinada com as características extraídas da imagem reescalada para 40% do tamanho original, máscara de 24 raios, C=15 e usadas 25 componentes principais. ....	116
Figura 6.36 – Resultado da segmentação com C=15, 25 componentes principais (imagem central) e 20 componentes principais (imagem à direita) para uma imagem de treino (cima) e uma imagem de teste (baixo) e máscara de 24 raios. ....	117
Figura 6.37 - Resultado da segmentação com C=15 (imagem central), C=5 (imagem à direita), 20 componentes principais para uma imagem de treino (cima) e uma imagem de teste (baixo) e máscara de 24 raios.....	118
Figura 6.38 - Resultado da segmentação com C=5, 20 componentes principais, máscara de 24 raios (imagem central) e 36 raios (imagem à direita) para uma imagem de treino (cima) e uma imagem de teste (baixo). ....	118
Figura 6.39 – Marcação dos pontos de medida usando a aproximação dos pontos extremos resultantes da segmentação. O resultado do detetor está assinalado com uma cruz vermelha e a verde a marcação manual tida como correta. ....	120
Figura 6.40 – Imagem original e resultado da segmentação por aplicação da SVM. ....	121
Figura 6.41 – Subimagem esquerda e direita. ....	121
Figura 6.42 – Pontos extremos detetados e o ponto central para desenho do círculo obtido a partir destes. ....	121
Figura 6.43 – Marcação dos círculos para determinação dos pontos de medida. Para a imagem esquerda é selecionado o último ponto de contacto do círculo com o contorno visto no sentido descendente. Para a imagem à direita o último ponto de contacto do círculo com o contorno no sentido ascendente. O método é alterado em função da orientação do feto. ....	122
Figura 6.44 – Resultados da marcação dos pontos de medição da DCC com o algoritmo descrito. A vermelho o resultado da marcação manual e a amarelo os pontos detetados pelo algoritmo. ....	122
Figura 6.45 – Marcação do centroide de cada subimagem e a reta com inclinação definida pela orientação da imagem global e da orientação de cada subimagem. O ponto de interseção da reta com o contorno define o ponto de medida.....	123
Figura 6.46 – Resultados da marcação dos pontos de medida com recurso à utilização do centroide de cada subimagem e da orientação da imagem global e orientação da imagem parcial. A amarelo a marcação automática e a vermelho a marcação manual.....	123
Figura 6.47 – Resultados da marcação dos pontos de medição da SVM para algumas das imagens de treino. À esquerda a imagem original com a marcação do obstetra, ao centro as marcações para o treino e à direita, assinalado a branco e envolvido pelo círculo os pontos classificados como pertencentes à região de medição pela SVM. ....	125
Figura 6.48 – Resultado do classificador para quatro imagens de teste. À esquerda duas imagens onde a classificação foi bem sucedida e à direita mal sucedida. ....	125



## LISTA DE TABELAS

Tabela 1.1 – Valores da densidade, velocidade de propagação do som e da impedância acústica de tecidos humanos. Retirado de (Azhari, 2010).	11
Tabela 6.1 – Valores dos coeficientes de validação obtidos para a primeira imagem da Figura 6.1. Nos métodos com dependência da vizinhança foi usada uma janela 5x5. Para FCMS <sub>1</sub> foram usados os mesmos pesos $p=q=2$ . Em FCMS <sub>2</sub> e FCMS <sub>2m</sub> foi usado $\alpha=5$ . Em FCMS <sub>3</sub> foi usado $\lambda_s=0.5$ e $\lambda_g=3$ .	99
Tabela 6.2 - Valores dos coeficientes de validação obtidos para a segunda imagem da Figura 6.1. Nos métodos com dependência da vizinhança foi usada uma janela 5x5. Para FCMS <sub>1</sub> foram usados os mesmos pesos $p=q=2$ . Em FCMS <sub>2</sub> e FCMS <sub>2m</sub> foi usado $\alpha=5$ . Em FCMS <sub>3</sub> foi usado $\lambda_s=0.5$ e $\lambda_g=3$ .	99
Tabela 6.3 – Valores dos coeficientes de validação obtidos para a terceira imagem da Figura 6.1. Nos métodos com dependência da vizinhança foi usada uma janela 5x5. Para FCMS <sub>1</sub> foram usados os mesmos pesos $p=q=2$ . Em FCMS <sub>2</sub> e FCMS <sub>2m</sub> foi usado $\alpha=5$ . Em FCMS <sub>3</sub> foi usado $\lambda_s=0.5$ e $\lambda_g=3$ .	100
Tabela 6.4 – Valor médio da ES considerando os resultados obtidos no conjunto das 3 imagens para cada método de FC.	100
Tabela 6.5 – Erro absoluto médio, em percentagem, da medição para cada um dos métodos apresentados considerando apenas as marcações sobre as imagens corretamente segmentadas.	123



## LISTA DE ABREVIATURAS, SIGLAS E ACRÓNIMOS

CP	Coeficiente da Partição
DBP	Diâmetro Biparietal
DCC	Distância Crânio-Caudal
EP	Entropia da Partição
ERM	<i>Empirical Risk Minimisation</i> (Minimização do Risco Estrutural)
ES	Exatidão da Segmentação
FC	<i>Fuzzy Clustering</i>
FCM	<i>Fuzzy C-Means</i>
FLS	Função <i>Level Set</i>
GKFCM	<i>Gaussian Kernel Fuzzy C-means</i>
$\beta$ -hCG	Gonadotrofina coriônica humana
IG	Idade Gestacional
LS	<i>Level Set</i>
ML	<i>Machine Learning</i>
MLP	<i>MultiLayer Perceptron</i>
PAPP-A	Proteína A plasmática associada à gravidez
PCA	<i>Principal Component Analysis</i> (Análise de Componentes Principais)
ROI	<i>Region of Interest</i> (Região de Interesse)
SG	Saco Gestacional
SRM	<i>Structural Risk Minimisation</i> (Minimização do Risco Estrutural)
SVM(s)	<i>Support Vector Machine(s)</i>
THG	Transformada de Hough Generalizada
TN	Translucência da Nuca
VC	Vapnik-Chervonenkis





## INTRODUÇÃO GERAL E OBJETIVOS

O exame fetal referente ao primeiro trimestre é uma ferramenta importante ao dispor dos obstetras para a avaliação da idade gestacional, do desenvolvimento fetal e da possibilidade de existência de possíveis anomalias, entre as quais se destacam as cromossômicas como a Trissomia 21. Ao contrário das anomalias morfológicas, as cromossômicas nem sempre são detetadas pela simples observação das imagens fetais. O seu diagnóstico por via da observação do exame ultrassonográfico exige a realização de medidas, extraídas por via manual de acordo com normas internacionais, que permitem calcular o risco associado. As mais frequentes são as medições realizadas na ecografia do 1º trimestre, nomeadamente a Distância Crânio-Caudal (DCC) que permite estimar a idade gestacional e avaliar o desenvolvimento fetal, e a medida da Translucência da Nuca (TN) que, quando cruzada com a DCC, é um forte indicador do risco de anomalias no cariótipo. Quando a ecografia é realizada após as 14 semanas a realização de outras medições, como o Diâmetro Biparietal (DBP), é tida como mais adequada para estimar a idade gestacional, sendo também utilizada na avaliação do desenvolvimento do feto.

Apesar de valores anormais do cruzamento da medida da TN com a DCC não significar à partida a existência de um problema, as estatísticas demonstram que permitem estimar com elevada precisão o risco associado, evitando e/ou reduzindo os exames de rastreio e, consequentemente, os custos e riscos associados para o feto e a própria mãe (e.g. amniocentese).

Os estudos existentes apontam para uma variabilidade significativa na obtenção das referidas medidas. A qualidade destas, e considerando à partida que são realizadas por médicos especialistas, é fortemente influenciada pela disponibilidade física do operador e pelo tipo de medição que está a ser realizada (medidas com carácter meramente observacional tendem a ter pior qualidade que quando realizadas com fins de diagnóstico), pelo que o mesmo operador apresenta, perante as mesmas imagens, medições distintas. Por outro lado, apesar de existirem normas e procedimentos instituídos para a realização dos exames, operadores distintos tendem a apresentar medições distintas. Estando o diagnóstico dependente da qualidade da medida, a variabilidade inter e intra-operador pode comprometer o seu resultado. Adicionalmente, uma vez que as medições são feitas manualmente, a realização de cada ecografia é demorada e o elevado número de *keystrokes* necessários para que o obstetra efetue as medições pode despoletar situações de *stress*, prolongando e dificultando ainda mais a obtenção das medidas corretas. O desenvolvimento de um sistema automático de apoio à

realização de medições por parte do obstetra pode contribuir para diminuir o *stress* associado à necessidade de, consecutivamente, realizar medições de elevado grau de dificuldade pela diminuição do número de *keystrokes* necessário. Um sistema automático de apoio permite melhorar o fluxo de trabalho e diminuir o tempo de realização de cada exame e, desta forma, melhorar a produtividade/nº. de pacientes examinados. Além disso pode contribuir para a melhoria da precisão e repetibilidade das medidas efetuadas. Em última análise, pode contribuir para uma melhor prestação de cuidados de saúde fetais, reduzindo o número de intervenções invasivas desnecessárias.

O problema do tratamento das imagens fetais, obtidas por um sistema baseado em ultrassons, não é contudo simples de realizar. A atestar esta afirmação está o número reduzido de trabalhos publicados sobre o assunto. As ecografias fetais apresentam uma relação sinal/ruído baixa, contraste reduzido e variações importantes no posicionamento e morfologia do feto que dificultam o seu processamento. Além destes fatores, situações como as que o corpo fetal se encontra em contacto com a parede uterina fazem com que o cenário visual a analisar apresente padrões subtis caracterizadores dos limites do feto, o que obriga a uma determinação de base mais global e não tanto de base local. A isto acresce o facto de existir variabilidade no aspeto geral da imagem adquirida entre equipamentos o que dificulta a tarefa de generalização de um sistema de decisão automático.

Das medidas referidas, uma das que maiores dificuldades apresenta é a DCC. A sua obtenção depende da possibilidade de encontrar dois pontos de medição, um colocado no crânio e outro junto à nádega, e que, de uma forma geral, dependem da correta identificação do corpo fetal. Atendendo ao que já foi referido, esta tarefa é de complexidade elevada pois nem sempre é possível estabelecer a separação correta entre o tecido fetal e outros tecidos que, nas imagens ecográficas, surgem representados com características muito semelhantes. Além disso as imagens possuem um nível de ruído extremamente elevado que pode significar a perda de detalhe ou a incorreta representação das estruturas relevantes (e.g. representação dos tecidos fetais como líquido amniótico), dificultando ainda mais a tarefa de segmentação automática. Mais, existe a possibilidade de o feto se encontrar em posições variadas, com a cabeça mais ou menos fletida, o que faz com que a deteção do ponto de medida correto na região do crânio seja ainda mais complexa.

A quantidade de estudos que abordam a questão das medições em imagens fetais é escassa, especialmente no que se refere à obtenção da DCC por via automática. Este trabalho pretende ser uma contribuição para resolução deste problema, tendo como objetivo último o desenvolvimento de uma metodologia integralmente automática que permita a realização da medição da DCC em ecografias fetais. Para alcançar este objetivo, este trabalho pretende analisar e sugerir novas soluções, baseadas

em diversas técnicas de segmentação, consideradas adequadas às imagens de ultrassons, mas que não foram, até ao momento, devidamente exploradas no que se refere à segmentação das imagens fetais, dando particular ênfase às imagens do corpo fetal destinadas à obtenção da medida DCC. Partindo de técnicas de *Fuzzy Clustering*, Contornos Ativos e *Support Vector Machines* pretende-se apresentar modelos de segmentação e de extração de medidas que conduzam a resultados satisfatórios. As metodologias selecionadas têm apresentado bons resultados na resolução de problemas nas mais diversas áreas e possuem características de base adequadas à solução do caso de aplicação.

Os métodos convencionais de *clustering*, geralmente referidos como *hard clustering*, restringem a atribuição de um ponto a uma única classe. Como consequência, em imagens com resolução espacial limitada, de baixo contraste, com ruído e heterogeneidade de intensidades, a tarefa de criar uma segmentação *crisp* é complexa, pelo que este tipo de metodologias claramente tende a falhar. Nestas situações, métodos baseados na teoria de lógica difusa, como o *Fuzzy Clustering* (FC), apresentam-se como a solução mais adequada pois permitem uma segmentação mais *soft*, resultado de um mesmo pixel poder ser atribuído, simultaneamente, a várias classes, possivelmente com graus de pertença distintos. Apesar disso, as abordagens típicas não incorporam no processo de decisão a informação espacial o que impede um bom desempenho em imagens muito heterogêneas ou com ruído intenso. Sabendo que existe uma correlação elevada entre pixéis vizinhos, o uso desta informação pode contribuir para reduzir a sensibilidade do classificador ao ruído e aos artefactos frequentemente associados às imagens de ultrassons. Desta forma, este trabalho pretende abordar e devidamente analisar este aspeto.

Os contornos ativos referem-se a modelos que permitem evoluir uma curva por forma a dirigi-la para uma região da imagem que minimiza uma função de custo e que, de uma forma geral, corresponde ao contorno de um ou mais objetos da imagem. A partir da própria imagem é possível extrair um conjunto de forças que permitem realizar a evolução da curva para um estado estacionário próximo ou coincidente com o contorno desejado. As técnicas habituais usam a informação do gradiente da imagem para cumprirem com este objetivo. No entanto, em casos de imagens com elevada heterogeneidade o gradiente pode conduzir a mínimos locais e, como tal, a uma má segmentação. Outro inconveniente associado à generalidade dos métodos de contornos ativos é que necessitam de uma inicialização da curva inicial. Assim, este trabalho visa também a exploração da possibilidade de utilização de métodos que não recorrem à utilização do gradiente e, como tal, mais ajustados ao caso de estudo. Além disso, propõe-se a utilização de uma metodologia baseada em *Level Sets* (LS) que

simplifica o processo de cálculo associado a este tipo de problemas e explora-se a utilização do resultado do FC na aceleração do processo de convergência do método de contornos ativos sugerido.

As *Support Vector Machines* (SVMs) incluem-se nos métodos de *Machine Learning* (ML). São conhecidas por possuírem caráter generalizador, que lhes permite obter resultados superiores ou, no pior dos casos, idênticos às redes neuronais convencionais. São largamente usadas nas mais diversas aplicações e com resultados muito promissores. Nas pesquisas realizadas não foram encontrados trabalhos que explorassem o uso das SVMs no processo de extração do corpo fetal ou da medida DCC. Como tal, a inclusão de um método deste gênero representa um importante contributo. Além disso, a capacidade de generalização da SVM é catalisada pela inclusão a montante do classificador de uma PCA, complementada com *whitening*, que permite remapear o espaço de características primárias num subespaço de menor dimensão com ganhos na dimensionalidade, custos computacionais e diferenciação dos dados e, acima de tudo, generalização. Sobre esta associação não são conhecidos quaisquer trabalhos publicados, pelo que o método apresentado apresenta um caráter inovador.

Para além dos métodos de segmentação propõem-se métodos de extração da medida da DCC.

As abordagens apresentadas, apesar de aplicadas ao problema da segmentação das imagens fetais com vista à obtenção do corpo fetal, pelas características que apresentam podem ser estendidas e aplicadas a outro tipo de utilização no contexto da extração de medidas com vista ao diagnóstico.

A associação dos mecanismos de segmentação propostos com o sistema de medição automático sugerido possibilita o futuro desenvolvimento de sistemas de diagnóstico automáticos ou semiautomáticos, representando um importante contributo para a melhoria do diagnóstico, para a redução da variabilidade intra e inter-operador e para a eliminação/redução da dependência da disponibilidade física e da motivação do operador.

Resumindo, este trabalho assume os seguintes objetivos/contribuições principais:

1. Realizar uma análise exploratória dos algoritmos de FC e contornos ativos mais adequados à segmentação das imagens fetais para extração do corpo do feto;
2. Desenvolver e aplicar uma estratégia de segmentação das imagens fetais baseada em mecanismos de aprendizagem estatística, SVMs, coadjuvada por métodos potenciadores da redução do espaço de características e do aumento da capacidade de generalização;
3. Desenvolver e aplicar estratégias, baseadas na segmentação do corpo fetal, para extração da medida DCC;
4. Desenvolver e aplicar uma estratégia de medição da distância DCC suportada por um classificador SVM semelhante ao indicado em 2.

## ORGANIZAÇÃO DO DOCUMENTO

O primeiro capítulo é um capítulo introdutório que aborda a problemática relacionada com a aquisição de imagens com recurso a ultrassons. Neste capítulo introduziu-se ainda a importância das medidas para o diagnóstico fetal e os problemas da variação intra e inter-operador.

O capítulo seguinte apresenta um estudo resumido dos principais trabalhos na área, fornecendo uma descrição sumarizada das metodologias usadas, assim como os resultados obtidos e as principais limitações. Serão discutidos essencialmente os trabalhos considerados mais relevantes na segmentação e extração de medidas de imagens fetais.

Nos capítulos 3, 4 e 5 são apresentados os fundamentos que estão na base de cada uma das metodologias aplicadas no âmbito deste trabalho com vista à resolução do problema/objetivo enunciado na secção Introdução Geral e Objetivos. São também fornecidas indicações sobre a pertinência dos métodos seleccionados no contexto da tese e descrita a implementação da SVM usada no processo de segmentação.

No capítulo 6 são analisados e discutidos os resultados obtidos. Neste mesmo capítulo são sugeridas metodologias para extração da medida da Distância Crânio-Caudal a partir das imagens segmentadas e com recurso a um classificador treinado especificamente para assinalar os pontos de referência.

Por último na secção Conclusões Gerais e Trabalho Futuro são apresentadas as conclusões gerais face aos resultados observados e às metodologias aplicadas e são fornecidas indicações com vista à melhoria dos resultados e à extensão da solução proposta a outras medidas fetais.



# 1. EXAME FETAL

## 1.1 Introdução

Atualmente, nos países considerados desenvolvidos, é rara a gravidez que não seja acompanhada por um obstetra. A sua função consiste em avaliar a evolução da saúde do feto e da progenitora durante o período de gestação e, no caso de anomalias, informar os pais das soluções médicas disponíveis para a resolução do seu problema.

O exame ultrassonográfico é, muito provavelmente, o meio de diagnóstico mais usado pelos médicos na avaliação da evolução de uma gravidez. O facto de ser de baixo custo e não invasivo são fatores que contribuem para a sua utilização em larga escala. Por outro lado, as imagens obtidas permitem avaliar com bastante rigor o estado do feto em cada fase da gestação. Em caso de dúvidas, o médico pode recorrer a outros tipos de exames para confirmar as suas suspeitas. De uma forma geral, estas alternativas são mais dispendiosas e invasivas (*e.g.* amniocentese), pelo que os médicos recorrem a elas apenas nos casos de suspeitas retiradas a partir do exame ecográfico ou em caso de gravidez de risco (*e.g.* idade materna avançada).

De uma forma geral, as organizações médicas recomendam para uma gravidez de baixo risco a realização de três exames ultrassonográficos, o primeiro realizado entre as 11 e as 13 semanas e seis dias (11-13<sup>+6</sup>), o segundo entre as 18-23 semanas e o último entre as 28-32 semanas (Nicolaidis, Sebire, & Snijders, 2000). Segundo a norma da Direção Geral de Saúde Portuguesa, o período aconselhado para o primeiro exame ecográfico é semelhante, diferindo ligeiramente nas ecografias do segundo e terceiro trimestres de gestação, devendo estes ser realizados entre as 20-22 e as 30-32 semanas, respetivamente (DGS, 2015). A ecografia do primeiro trimestre assume particular importância na medida em que permite diagnosticar possíveis anomalias numa fase muito inicial da gestação, permitindo aos médicos realizar procedimentos mais drásticos numa fase em que os riscos para a mãe serão menores (*e.g.* interrupção da gravidez). Neste primeiro exame devem ser avaliados os seguintes itens: Distância Crânio-Caudal (DCC), frequência cardíaca, medida da Translucência da Nuca (TN), quantificação do risco de trissomia 21, anatomia do feto (pólo cefálico, coluna vertebral, estômago, parede abdominal e membros) e corionicidade (DGS, 2015), os quais permitem estabelecer com elevado grau de certeza a idade gestacional, a gravidez múltipla, a viabilidade e vitalidade fetal e

possíveis malformações fetais ou anomalias cromossômicas como a Trissomia 21 (Nicolaidis *et al.*, 2000).

As malformações fetais e as gravidezes múltiplas são avaliadas por observação direta das imagens e são facilmente reconhecidas por um especialista e, em muitos casos, até mesmo por um leigo. Já o caso do diagnóstico das anomalias cromossômicas ou da avaliação da idade gestacional requer o uso de medidas extraídas a partir das imagens fetais, tais como a medida da TN, a DCC ou o Diâmetro Biparietal (DBP), que são depois correlacionadas com a idade materna para se avaliar o estado de desenvolvimento do feto ou o risco de anomalia cromossômica. A datação correta da gravidez/idade gestacional tem grande impacto na qualidade dos cuidados obstétricos em geral, estando demonstrado que permite reduzir significativamente as induções do trabalho de parto por gestação pós-termo (Welsh, 2008). A idade gestacional pode ser determinada com base na data da última menstruação ou com base na DCC. A primeira opção é válida apenas nos casos de mulheres que tenham certeza relativamente a datas, com ciclos regulares e que não tenham usado contraceptivos hormonais nos dois meses anteriores à concepção ou sejam lactantes, estando assim mesmo associada a um erro elevado uma vez que não é conhecido o momento exato da ovulação, fertilização e implantação no útero (Butt & Lim, 2014). Pelo contrário, o exame ecográfico de primeiro trimestre permite estimar com elevada precisão a idade gestacional com base na DCC, sendo considerado ter resultados clinicamente superiores. No que respeita a quantificação do risco de Trissomia 21, esta deve ser baseada na TN e na idade materna, usando para este fim uma base de dados. Contudo, sempre que possível, aconselha-se ainda a combinação com a realização de testes bioquímicos, nomeadamente a determinação da fração livre da gonadotrofina coriônica humana ( $\beta$ -hCG) e da proteína A plasmática associada à gravidez (PAPP-A). A utilização da referida combinação tripla permite aumentar a taxa de deteção para 85-95%, com 5% de falsos positivos (Nicolaidis & do Brasil DeFigueiredo, 2004).

Neste contexto, o exame ecográfico, realizado no primeiro trimestre da gestação (11-13<sup>+6</sup> semanas) representa um instrumento valioso para a avaliação das características principais do estado fetal, permitindo reduzir o número de intervenções invasivas desnecessárias e desta forma contribuir de forma relevante para a diminuição dos problemas associados.

No entanto, as imagens obtidas por ecografia apresentam algumas limitações que dificultam a extração das medidas e, consequentemente, o diagnóstico. Desde logo, as imagens são afetadas por um tipo de ruído, designado por *speckle*, que contribui significativamente para a degradação da informação relevante. Por outro lado, os sistemas de ultrassons apresentam limitações físicas relativamente à resolução espacial o que contribui também para a diminuição dos pormenores das estruturas/tecidos



analisados. A resolução espacial está diretamente ligada à frequência usada, sendo que o aumento da frequência melhora o detalhe espacial mas reduz a profundidade das regiões possíveis de analisar. É pois, necessário encontrar um compromisso entre o comprimento de onda a usar e o tipo de exame pretendido.

Neste capítulo serão abordadas de forma mais detalhada as questões mais relevantes associadas à utilização dos sistemas de ultrassons na construção de imagens médicas. Serão também analisadas as medidas mais relevantes para o exame fetal das 11-14 semanas e sua relação com algumas das anomalias mais frequentes.

## 1.2 Ultrassons

O som é energia mecânica propagada por um meio contínuo através de um processo de compressão e descompressão, como se tratasse de uma mola mecânica, Figura 1.1.




Figura 1.1 – Visualização da energia da onda sonora como um modelo mecânico de compressão-descompressão de uma mola. As zonas escuras correspondem a amplitudes elevadas de maior energia (compressão) e as zonas a branco a zonas de baixa energia (descompressão) (retirado de (Bushberg, Seibert, Leidholdt, & Boone, 2011)).

Os ultrassons referem-se a ondas sonoras cuja frequência é superior ao limite máximo do ouvido humano, cerca de 20kHz.

A aplicação de ultrassons em meios de diagnóstico recorre às frequências na gama dos 1-18MHz. No caso concreto dos equipamentos obstétricos são geralmente usadas frequências entre os 1 e os 10MHz (Nicolaidis, 2004; Nicolaidis *et al.*, 2000). Existem, no entanto aplicações muito específicas

no âmbito do diagnóstico médico que recorrem a frequências muito superiores, podendo ir aos 50 MHz (Bushberg *et al.*, 2011).

A utilização de frequências mais elevadas melhora a resolução espacial do equipamento mas reduz a profundidade de ação em virtude de a atenuação nos tecidos aumentar quase linearmente com a frequência (na gama de frequências usadas), como resultado da absorção de energia pelo meio (Azhari, 2010). É, portanto, necessário estabelecer um compromisso entre a frequência a usar e o tipo de aplicação que se pretende. A amplitude da onda de ultrassom ao longo da linha de propagação, negligenciando o efeito da dependência da frequência, pode ser aproximada pela Equação (1.1). A Figura 1.2 apresenta a variação da atenuação com a distância percorrida pela onda, considerando um meio homogêneo.

$$A(x) = A_0 e^{-\alpha x} \quad (1.1)$$

Na Equação (1.1)  $A_0$  representa a amplitude da onda incidente,  $x$  a distância e  $\alpha$  o coeficiente de atenuação e que é característico do meio (Azhari, 2010; Suri, Setarehdan, & Singh, 2002).




Figura 1.2 – Atenuação normalizada da propagação da onda num meio homogêneo como função da distância.

A velocidade do som,  $v$ , num material específico é determinada pelas propriedades do próprio material (Kane, 2009) e pode ser calculada pelo produto da frequência,  $f$ , pelo respetivo comprimento de onda,  $\lambda$  (Equação (1.2)). A velocidade de propagação da onda sonora é dependente da densidade do meio que atravessa. Quanto maior for a densidade maior será também a velocidade de propagação. Os tecidos existentes no corpo humano apresentam densidades diferenciadas pelo que

a velocidade de propagação varia de acordo com o tecido que atinge. A frequência do ultrassom não é afetada pela variação da velocidade de propagação nos diferentes meios (Bushberg *et al.*, 2011). A Tabela 1.1 apresenta uma lista dos valores típicos para tecidos humanos.

Tabela 1.1 – Valores da densidade, velocidade de propagação do som e da impedância acústica de tecidos humanos. Retirado de (Azhari, 2010).

<b>Tecido</b>	<b>Densidade (g/cm<sup>3</sup>)</b>	<b>Velocidade</b>	<b>Impedância acústica</b>
Cérebro	1,03	1550	1,60
Fígado	1,06	1590	1,69
Rim	1,05	1570	1,65
Sangue	1,055	1575	1,66
Músculo	1,065	1585	1,68
Osso	1,9	4080	7,75

A relação da velocidade de propagação,  $v$ , com a densidade,  $\rho$ , é aproximada pela Equação (1.3).

$$v = f \times \lambda \quad (1.2)$$

$$v = \sqrt{\frac{K}{\rho}} \quad (1.3)$$

$K$  representa a constante de elasticidade do material ou rigidez (Kane, 2009).

A impedância acústica,  $z$ , é aproximada pela Equação (1.4) e pode ser vista como a rigidez ou flexibilidade de uma mola. A interligação de molas com diferentes constantes de elasticidade condicionam a propagação da energia entre estas dando origem a fenómenos tais como o de reflexão e refração. Quando os coeficientes de elasticidade são muito distintos a maior parte da energia não é propagada de uma mola para a outra, mas sim refletida. O mesmo acontece quando uma onda sonora atinge interfaces com diferentes impedâncias acústicas. Numa região em que exista uma diferença significativa da impedância acústica entre os tecidos, a maior parte da onda sonora é refletida. Este fenómeno está na base da produção de imagens com base em mecanismos de ultrassons do tipo pulso-eco (Bushberg *et al.*, 2011).

$$z = \rho \times v \quad (1.4)$$

Quando a onda atinge a região fronteira (região de transição entre dois tecidos distintos) uma parte da onda é refletida e a restante é propagada. Já foi referido que a taxa de reflexão depende da diferença

entre as impedâncias acústicas dos dois tecidos, pelo que a componente reflectida pode ser calculada pela Equação :

$$I_r = I_i \left( \frac{z_2 - z_1}{z_2 + z_1} \right)^2 \quad (1.5)$$

onde  $I_r$  representa a intensidade da onda reflectida e  $I_i$  da onda incidente e  $z_1$ ,  $z_2$  as impedâncias acústicas do meio 1 e 2, respetivamente.

A fração da onda que continua a ser propagada pode continuar na mesma direção da onda incidente ou pode ver essa direção alterada. Este fenómeno é conhecido por refração e o ângulo de refração pode ser calculado pela Equação (1.6) (Suri *et al.*, 2002), conhecida pela lei de *Snell*:

$$\frac{\sin \theta_i}{\sin \theta_r} = \frac{v_1}{v_2} \quad (1.6)$$

onde  $\theta_i$  representa o ângulo de incidência,  $\theta_r$  o ângulo da refração,  $v_1$  e  $v_2$  a velocidade de propagação no tecido 1 e 2, respetivamente. A Figura 1.3 ilustra os aspetos referidos. Note-se que neste modelo apenas se considera a reflexão segundo uma direção. Isto pressupõe que a superfície é suave e, portanto, a totalidade da energia refletida segue uma única direção. É, no entanto, conveniente entender que nem sempre é este o caso, pelo que podem ocorrer reflexões noutras direções. Este fenómeno é conhecido por espalhamento ou dispersão (*scattering*) e aparece quando a fronteira não é regular ou suave como ilustrado na Figura 1.4.




Figura 1.3 – Reflexão e refração de uma onda sonora numa interface (adaptada de (Suri *et al.*, 2002)).

O espalhamento acústico surge também nas situações em que as estruturas celulares possuem um tamanho igual ou inferior ao comprimento de onda do ultrassom e está essencialmente associado às interfaces dentro do mesmo tecido (Bushberg *et al.*, 2011; Suri *et al.*, 2002). A Figura 1.4 ilustra este fenómeno.




Figura 1.4 – Espalhamento provocado por estruturas cuja dimensão é menor que o comprimento de onda e pela irregularidade da superfície entre dois tecidos (interface) (adaptado de (Bushberg *et al.*, 2011)).

A intensidade do espalhamento relaciona-se com o comprimento de onda do sinal,  $\lambda$ , e com o raio das estruturas celulares,  $r$ , e pode ser determinada pela Equação (1.7) (Suri *et al.*, 2002).

$$I_s \propto \frac{r^6}{\lambda^4} \quad (1.7)$$

Ao contrário das reflexões especulares (resultado das interfaces suaves entre tecidos distintos), as não-especulares (espalhamento) do parênquima (tecido funcional que constitui o órgão) não dependem significativamente do ângulo da onda incidente. Os ecos resultantes apresentam, por isso, amplitudes muito semelhantes e são representados na imagem produzida por intensidades próximas. Já o espalhamento resultante das diferenças entre duas regiões podem apresentar amplitudes diferentes e, consequentemente, serem representadas por intensidades distintas aquando da produção da imagem (Bushberg *et al.*, 2011).

Um fenómeno, que afeta a qualidade da imagem, resultante das reflexões não-especulares é designado por *speckle*. Resulta da sobreposição de diversos fatores, sendo que o mais importante diz respeito à interferência construtiva/destrutiva dos ecos refletidos pela via da dispersão (espalhamento) (Suri *et al.*, 2002). Este fenómeno afeta de forma significativa a qualidade da imagem, traduzindo-se num aspeto granulado da mesma. Os sistemas de aquisição incluem alguns mecanismos para reduzir os efeitos do *speckle*. Como a imagem é produzida a partir de vários ângulos de interação com o objeto, a probabilidade de que um desses ângulos seja perpendicular a um refletor especular é aumentada, pelo que ecos com maior amplitude são gerados, melhorando a qualidade da imagem obtida. Realizando um processo de média das diversas componentes da imagem global pode-se reduzir o *speckle noise* e melhorar a relação sinal/ruído (Bushberg *et al.*, 2011).

A resolução espacial determina o detalhe com que a imagem é produzida. No caso dos ultrassons a resolução espacial depende do volume do pulso acústico e pode ser vista em três dimensões:

resolução axial, resolução lateral e resolução vertical (Bushberg *et al.*, 2011; Suri *et al.*, 2002) tal como representado na Figura 1.5.




Figura 1.5 – Componentes axial, lateral e vertical para um *array* de ultrassons (retirada de (Bushberg *et al.*, 2011)).

A resolução axial determina a distância mínima, entre dois objetos, possível de ser detetada na linha da onda emitida. Uma boa resolução axial pode ser obtida de duas formas. A primeira consiste em garantir que as interfaces se encontram separadas por uma distância maior que  $\frac{1}{2}$  do comprimento de onda total do pulso emitido (na generalidade dos casos são enviados 3 períodos por pulso). Caso contrário os ecos formados podem sobrepor-se. A outra forma consiste em aumentar a frequência do pulso. Esta solução permite reduzir a distância mínima possível ser detetada sem que ocorra sobreposição das reflexões. A Figura 1.6 pretende ilustrar estas duas situações.




Figura 1.6 – Dependência da resolução axial com a distância entre interfaces e a frequência do pulso emitido (retirada de (Bushberg *et al.*, 2011)).

Note-se, no entanto, que o aumento da frequência apresenta algumas implicações. Desde logo no que se refere aos já referidos problemas de atenuação e profundidade. Por outro lado, estruturas com dimensão inferior a  $\frac{1}{2}$  do comprimento de onda total do pulso continuarão a causar o problema da sobreposição das reflexões, o que significa que, independentemente da frequência usada existe sempre um limite espacial mínimo.

A resolução lateral, Figura 1.5, também conhecida por azimuth, estabelece a distância mínima possível de separação de objetos numa direção perpendicular ao pulso. É determinada pelo diâmetro do pulso, pelo que a distância implica alterações na resolução lateral (Bushberg *et al.*, 2011). O efeito da variação da resolução lateral com a profundidade pode ser observado na Figura 1.7.




Figura 1.7 – Efeito da variação da resolução lateral com a profundidade na construção da imagem (adaptado de (Bushberg *et al.*, 2011)).

A melhor resolução lateral é obtida na transição do campo próximo/campo distante (assinalada a tracejado na Figura 1.7). Neste ponto o diâmetro corresponde a cerca de  $\frac{1}{2}$  do diâmetro do transdutor (Bushberg *et al.*, 2011). A resolução lateral dos *arrays* de transdutores pode ser melhorada/controlada modificando o ponto focal e reduzindo a largura do feixe efetivo. De facto as sondas de múltiplos elementos atuais possuem mecanismos de focagem dinâmica (alteração sucessiva do ponto focal) para melhorar a resolução lateral (Suri *et al.*, 2002). Dependendo do tipo de *array* usado (linear ou curvilíneo) isto pode ser conseguido alterando a direção do feixe ou através da temporização dos disparos dos pulsos (Bushberg *et al.*, 2011), tal como apresentado na Figura 1.8.

Por último, a resolução “vertical” é definida como a distância mínima entre dois objetos posicionados verticalmente capazes de serem detetados de forma separada (Suri *et al.*, 2002) e pode ser vista na dimensão do feixe perpendicular ao plano da imagem. Tal como a resolução lateral está dependente da largura do transdutor, a resolução vertical está dependente da sua altura. É, tipicamente, a medida de menor qualidade num *array* de transdutores (Suri *et al.*, 2002). Pode, no entanto, ser melhorada recorrendo a um processo semelhante ao da melhoria da resolução lateral. Num *array* de transdutores com múltiplas linhas, é realizada uma excitação por fase dos transdutores (de dentro para fora na vertical) para variar o ponto focal na dimensão referida e assim melhorar também a resolução vertical. Note-se, no entanto, que, de uma forma geral, a dimensão vertical é fixa pois só existe uma única fila de transdutores. A Figura 1.9 apresenta uma explicação visual deste processo.




Figura 1.8 – Modificação do ponto focal por variação da temporização de excitação dos transdutores do array (retirado de (Bushberg *et al.*, 2011)).




Figura 1.9 – Variação da resolução vertical para múltiplos pontos focais com múltiplos transdutores (retirado de (Bushberg *et al.*, 2011)).

Um dos problemas dos sistemas de ultrassons tem a ver com o facto de nem toda a energia ser propagada numa direção perpendicular à face do transdutor. Parte dessa energia é emitida em direções que não a principal, formando os chamados lobos laterais, tal como mostra a Figura 1.10.




Figura 1.10 – Energia propagada em direções que não a principal sob a forma de lobos laterais (adaptado de (Bushberg *et al.*, 2011)).

A formação dos lobos laterais é característica do transdutor e é causada pelo movimento de expansão e contração radial. Nos casos em que estes lobos são refletidos por estruturas posicionadas nessa direção, os ecos são mapeados como se tratassem de objetos na direção principal (Bushberg *et al.*, 2011; Suri *et al.*, 2002). Este facto induz à formação de artefactos na imagem, formando estruturas na imagem numa direção incorreta. Nos casos de utilização de sondas multi-elemento (*arrays* de



transdutores) o problema é minimizado pela redução da largura do elemento transdutor, geralmente inferior a  $\frac{1}{2}$  do comprimento de onda, ou alternativamente controlando a amplitude de excitação dos elementos laterais (menor amplitude nos laterais relativamente aos centrais) (Bushberg *et al.*, 2011).

### 1.3 Formação da imagem

Tal como referido, a ecografia é o meio de diagnóstico mais usado por obstetras para avaliar o estado do feto durante o período de gestação. O facto de ser relativamente barato, não invasivo e não apresentar efeitos secundários para o feto e a grávida contribuem em larga escala para a sua utilização (Hughes, Spring, & Podoleanu, 2010). Por outro lado, as imagens obtidas por este método contêm informação que, na generalidade dos casos, permite avaliar o estado do feto em termos de desenvolvimento e anomalias.



Figura 1.11 – Fotografia de um equipamento típico para aquisição de imagens por ultrassons.

O exame ecográfico é realizado recorrendo a imagens geradas com recurso a ultrassons. O diagnóstico por ultrassons é realizado por sistemas do tipo pulso-eco com sinais de frequência, geralmente, na gama dos 1 MHz aos 10 MHz, Figura 1.11.

Este tipo de sistemas emite um sinal de curta duração (pulso), gerado com recurso a transdutores piezoelétricos, para os tecidos. O transdutor tem a propriedade de transformar um sinal elétrico numa onda mecânica que é posteriormente refletida (eco). O mesmo transdutor tem a capacidade de realizar o processo inverso e transformar o eco recebido num sinal elétrico que é detetado e analisado. Dado que a velocidade de propagação do ultrassom varia muito pouco com o tipo de tecido (tecidos com densidades semelhantes), a distância percorrida pelo pulso é proporcional ao tempo (Suri *et al.*, 2002). Isto significa que, para os ecos recebidos, é possível determinar o tempo de viagem e calcular a posição relativa das interfaces acústicas.




Figura 1.12 – Princípio de funcionamento de um sistema de ultrassons pulso-eco (adaptado de (Suri *et al.*, 2002)).

O sinal elétrico recebido é depois convertido num sinal visual que possa ser interpretado pelo especialista. Os métodos mais comuns usados para proceder à visualização são: *A-scan*, *B-scan* e *M-scan* (ou em alternativa modo A, modo B e modo M).

O modo A, Figura 1.13, começa por realizar uma rectificação e a detecção da envolvente dos ecos recebidos. O sinal resultante é depois visualizado segundo uma linha temporal, que também poderá representar a distância (obtida pelo tempo de voo e pela velocidade de propagação da onda no tecido). Quanto maior for o sinal recebido maior será a amplitude do sinal representado. Os picos representam as interfaces (separação entre tecidos de tipo e densidades distintas) detectadas na linha da onda emitida e serão tanto maiores quanto maior for a diferença de densidade/impedância acústica entre os tecidos da interface. Note-se que o pico assinalado depende também do ângulo de incidência da onda na interface, pela forma da interface e pela densidade dos próprios tecidos que percorre. O seu valor será maior nos casos em que a onda refletida é coaxial à onda incidente. Uma superfície plana contribui para a coaxialidade das ondas incidente e refletida enquanto que, por exemplo uma superfície convexa, pode provocar desvios na axialidade dependendo da zona incidente. Por outro lado a absorção da onda sonora é diretamente proporcional à densidade do tecido. Isto significa que tecidos com elevada densidade absorvem uma maior quantidade da onda, o que pode contribuir para uma diminuição do pico recebido. A propagação da onda nos tecidos do mesmo tipo ou tecidos com densidades semelhantes não produz ecos relevantes.

Este modo é usado essencialmente na medição da dimensão de estruturas (Suri *et al.*, 2002) e é muito utilizado na área oftalmológica.

O modo B, Figura 1.14, toma esta designação pois os ecos recebidos sofrem uma modulação em intensidade (brilho). Na prática resulta da conversão de cada pico obtido pelo modo A num ponto cuja intensidade é proporcional à amplitude. O resultado é um conjunto de pontos, na linha da onda emitida, com intensidades distintas e relacionadas com o valor da amplitude dos ecos recebidos.




Figura 1.13 – Princípio de funcionamento do modo A (adaptado de (Suri *et al.*, 2002)).




Figura 1.14 – Princípio de funcionamento do modo B (adaptado de (Suri *et al.*, 2002)).

O modo M, Figura 1.15, assim designado por representar movimento, resulta do modo B. Cada linha, obtida pelo modo B, é refrescada e novamente representada. Desta forma cada linha é representada em instantes distintos podendo representar diferentes posições do objeto em movimento. Este método é especialmente usado para estudar objetos em movimento (Suri *et al.*, 2002).




Figura 1.15 – Princípio de funcionamento do modo M (adaptado de (Suri *et al.*, 2002)).

A representação da informação obtida pelas sondas pelos modos referidos são representações unidimensionais. Para se obter uma representação bidimensional (2D) é necessário realizar múltiplos *scans* em direções distintas da região pretendida. Existem implementados dois métodos: sistema mecânico ou sistema electrónico.

O sistema mecânico, usado nos primeiros sistemas de aquisição, consistia em posicionar um ou mais elementos sensores numa estrutura circular com possibilidade de rotação. Durante a rotação são emitidos pulsos em diversas direções e os ecos recebidos, pelo modo B, usados para construir a

imagem por justaposição dessas mesmas linhas. Para melhorar a imagem é realizado um processo de interpolação entre linhas adjacentes para completar os espaços entre estas (Suri *et al.*, 2002).




Figura 1.16 – Funcionamento típico de uma sonda rotativa.

A tecnologia mais recente recorre a sistemas eletrónicos, caracterizados por possuírem múltiplos elementos em arranjos que podem variar: *array* linear, *array* curvilíneo (Figura 1.17) ou *phased-array*.




Figura 1.17 – Arranjo dos transdutores num *array* linear e num *array* curvilíneo. As setas indicam o sentido da excitação dos transdutores (adaptado de (Bushberg *et al.*, 2011)).

Os *arrays* lineares e curvilíneos, Figura 1.17, podem conter entre 256 a 512 elementos de largura entre  $\frac{1}{2}$  a 1 comprimento de onda (Bushberg *et al.*, 2011). Para produzir a imagem é realizado um varrimento da superfície abrangida pela sonda. Em cada instante são ativados simultaneamente um conjunto de elementos adjacentes (entre 15 a 20), por forma a cobrir uma área definida pelo conjunto de sensores excitados. A informação obtida é usada para construir uma linha da imagem. Para se obter a imagem completa o processo é repetido grupo a grupo de elementos. Normalmente são estabelecidas tantas linhas quanto o número de elementos do *array*. Note-se que a geometria do arranjo define a geometria do campo de visão da sonda (rectangular ou trapezoidal).




Figura 1.18 – Princípio de funcionamento de um *phased-array* (adaptado de (Bushberg *et al.*, 2011)).

O *phased-array*, Figura 1.18, possui um arranjo semelhante ao *array* linear, podendo ser encontradas sondas em arranjos de 64, 128 ou 256 sensores (Bushberg *et al.*, 2011). Ao contrário do *array* linear, são usados todos os elementos sensores para produzir cada linha da imagem, pelo que é necessário implementar mecanismos que permitam orientar o feixe na direção pretendida. Para tal, o sistema aproveita o fenómeno de interferência. Alterando o instante em que cada transdutor emite o seu pulso é possível direcionar a onda resultante da interação de todos os pulsos. Este controlo é realizado eletronicamente de forma muito rápida e precisa. O ângulo incidente é determinado pela composição das ondas emitidas, tal como mostra a Figura 1.18. Fazendo variar continuamente o instante de cada pulso podemos variar o ângulo da onda emitida tal como se tratasse de um sistema mecânico ou de um *array* curvilíneo. A construção da imagem é o resultado da justaposição das linhas obtidas, tal como nos casos anteriores.

A Figura 1.19 apresenta uma imagem típica de um sistema 2D B-scan.



Figura 1.19 – Imagem fetal típica de um sistema *Real-Time* B-scan.

## 1.4 Medidas

Como já referido na introdução deste capítulo, durante o exame ecográfico é possível realizar diversas observações e medições que permitem inferir o estado de desenvolvimento do feto e diagnosticar possíveis malformações fetais ou alterações cromossómicas. Na obtenção das medidas é necessário ter especial cuidado pois delas depende um correto diagnóstico. Mais ainda, medições corretas favorecem a prestação adequada de cuidados de saúde fetal (Carneiro, Georgescu, Good, & Comaniciu, 2008).

O processo de medição não é automático uma vez que requer a intervenção do especialista que, de forma manual, coloca marcadores (*caliper*) na imagem em pontos específicos. Este facto introduz à partida um fator humano que pode contribuir para erros na medição e variabilidade intra e inter-operador (Nicolaidis *et al.*, 2000). A variação da medição intra-operador é afetada pela disponibilidade física e índices de atenção colocados na realização do exame, pelo que a sua redução depende apenas do esforço do próprio operador. Refira-se que as medições realizadas com fins interventivos tendem a ser muito mais rigorosas que aquelas realizadas com intuito meramente “observacional”. Um estudo demonstra que a medição é realizada com 100% de eficácia na primeira situação e com apenas 85% na segunda (Nicolaidis *et al.*, 2000). A variabilidade inter-operador só é reduzida se os especialistas seguirem regras comuns na execução do exame (o que, naturalmente, afeta também a variabilidade intra-operador). As organizações médicas internacionais que regulam a especialidade obstétrica definiram um conjunto de recomendações, critérios e procedimentos que os médicos devem seguir. Neste âmbito sugerem relativamente à medição da DCC e da TN (Nicolaidis *et al.*, 2000):

- i. Antes de realizar a medição deve ser obtido um corte sagital adequado e o feto deve ocupar cerca de 75% da imagem por forma a que cada movimento do *caliper* represente 0.1 mm;
- ii. As medições devem ser realizadas com o feto em posição neutral e deve ser prestada atenção à posição do cordão umbilical;

É frequente que o feto se apresente com o pescoço esticado, fletido ou até mesmo com o cordão umbilical à sua volta. Estes casos conduzem a medições erradas da DCC ou da TN e, consequentemente, induzem a um diagnóstico incorreto. Como exemplo, refira-se que um feto com pescoço estendido pode apresentar um valor aumentado da TN até 0,6 mm e, quando fletido, reduzido de cerca de 0,4 mm. No caso em que o cordão umbilical envolve o pescoço, o que ocorre entre 5% a 10% dos casos, o tamanho pode ser aumentado em cerca de 0.8 mm. Nestas condições, são tomadas

duas medidas da TN, uma acima do cordão e outra abaixo, sugerindo-se usar a menor na determinação do risco (Nicolaides *et al.*, 2000) ou, mais recentemente, a média das duas medições (Nicolaides & DeFigueiredo, 2004).

O especialista deve ter um cuidado especial quer na obtenção da imagem a usar quer na colocação dos marcadores para a realização da medição.

## 1.5 Distância Crânio-Caudal

A medida da Distância Crânio-Caudal (DCC) é correntemente considerada a forma mais fiável de estimar a data de ocorrência da gravidez, permitindo obter uma precisão de  $\pm 4$  dias quando realizada até às 10 semanas e de  $\pm 7$  dias quando realizada entre as 11-14 semanas de gestação, com um erro de  $\pm 2$  dias inter e intra-observador (Dhombres *et al.*, 2014). A DCC é usada para estabelecer com alguma precisão a Idade Gestacional (IG), o que permite prever com antecedência a data provável para o parto, permitindo ainda avaliar o crescimento do feto. A primeira equação que correlaciona a IG (medida em dias) com a DCC foi proposta por Robinson e Fleming (1975). Apesar desta equação (Equação (1.8)) ser ainda frequentemente usada, outras têm sido propostas, não existindo consenso relativamente a qual a fórmula mais apropriada para estabelecer a IG (Napolitano *et al.*, 2014).

$$IG = 8,052 \times (DCC \times 1,037)^{\frac{1}{2}} + 23,73 \quad (1.8)$$

De um ponto de vista prático, a IG, em semanas e com DCC em centímetros, relaciona-se com a DCC pela Equação (1.9) (Watson & Seeds, 2004) e é obtida com maior exatidão quando realizada durante o primeiro trimestre.

$$IG = DCC + 6,5 \quad (1.9)$$

A Figura 1.20 apresenta a curva de variação da IG em função da DCC para cada uma das equações apresentadas.

A DCC é também necessária para avaliar possíveis anomalias cromossómicas como o Síndrome de *Down* ou Síndrome de *Turner*, uma vez que a TN, indicador primário destas anomalias, aumenta de acordo com a DCC. Assim, é essencial correlacionar a medida da TN com a DCC, permitindo a correção do risco basal de possíveis anomalias fetais calculado com base na idade materna (Nicolaides *et al.*, 2000). Para tal, a idade gestacional deve estar compreendida entre 11–13<sup>+6</sup> semanas e o DCC deve medir de 45 a 84 mm. De igual forma, a datação precisa da IG é um componente essencial para

a correta interpretação de testes bioquímicos, sem a qual a sensibilidade deste rastreio de aparente simplicidade diminui para cerca de apenas 10% (Nicolaides & do Brasil DeFigueiredo, 2004).




Figura 1.20 – Idade Gestacional, em semanas, em função da DCC para as Equações (1.8) e (1.9).

A realização da medida deve ser realizada em imagens fetais recolhidas através de um corte sagital adequado, com o feto em posição neutra e a ocupar cerca de 75% da imagem. A Figura 1.21 apresenta um exemplo de uma imagem correta para efetuar esta medida. Os marcadores devem ser colocados na imagem de acordo com a Figura 1.22, ou seja, colocados no interior do contorno da região pretendida (no caso da medida da TN os marcadores devem estar verticalmente alinhados entre si).




Figura 1.21 – Exemplo de uma imagem fetal correta para medição da DCC com a marcação da medida (Imagem gentilmente cedida pelo Dr. Matos Cruz).






Figura 1.22 – Exemplos de *calipers* colocados de forma correta e incorreta para a realização de uma medição.

Todos os profissionais de saúde que realizam exames ecográficos fetais devem ser capazes de obter um corte longitudinal apropriado da coluna do feto e medir adequadamente a DCC. Estudos recentes sugerem que variações na medição da DCC podem ter um impacto significativo na avaliação de risco de anomalias cromossômicas realizada durante o primeiro trimestre de gravidez (Salomon, Bernard, Amarsy, Bernard, & Ville, 2009). Tal acontece porque erros na medição da DCC afetam a interpretação dos resultados da medição da TN e dos marcadores bioquímicos. Apesar da medição da DCC parecer, à primeira vista e para um leigo, a mais fácil de realizar, recentemente Dhombres e colaboradores (2014) demonstraram a ocorrência de erros algo frequentes nesta mediação. Os referidos autores usaram os dados de 68250 ecografias provenientes de 1913 profissionais, obtidas pelo Colégio Francês de Ecografias Fetais no âmbito do programa nacional de avaliação da qualidade das ecografias do primeiro trimestre, tendo avaliado a qualidade das imagens relativamente a 8 itens, incluindo a TN e DCC. Para cada item a imagem foi classificada considerando 4 níveis de qualidade (excelente, aceitável, insuficiente, inaceitável), correspondendo a diferentes pontuações. Considerando que cada ultrassonografista submeteu duas imagens por avaliação, para cada ecografia realizada poderia ser obtido um máximo de 32 pontos, permitindo classificar a ecografia com base no total de pontos obtidos em excelente (27-32), adequada (22-26), intermédia (20-21) e inaceitável (8-19). Um sistema semelhante foi aplicado para avaliação de apenas 7 itens, não considerando a DCC. De uma forma geral, verificou-se que 21,7% das ecografias eram de qualidade insuficiente no que respeita a medição da DCC e que de entre as 23764 ecografias classificadas como excelentes, tendo por base a classificação global, 965 ecografias (4,1%) apresentavam níveis insuficientes na qualidade da medição DCC. Considerando que os erros na medição da DCC podem afetar o cálculo do risco de aneuploidias, diferentes autores têm sugerido a implementação de um controlo de qualidade a esta medida, similarmente ao que acontece para a medida da TN, por forma a proporcionar os mais elevados padrões de qualidade possíveis.

## 1.6 Diâmetro Biparietal

Como referido, a DCC é a medição mais frequentemente usada para a determinação da IG no primeiro trimestre de gravidez. Para este propósito, esta deve ser realizada preferencialmente entre as semanas 9-13<sup>+6</sup>, nas quais o crescimento avaliado é linear e rápido, estando associado a um desvio padrão baixo, pelo que permite uma estimativa com elevada precisão. Após essa data, o feto assume uma posição vertical, tornando a obtenção da imagem adequada mais difícil, ocorrendo ainda um aumento da variabilidade biológica entre indivíduos. Desta forma, quando se pretende estimar a IG em ecografias realizadas posteriormente ao período referido e quando a DCC é superior ao máximo de 84 mm (por exemplo, em ecografias do segundo trimestre), deve optar-se pela medição do Diâmetro Biparietal (DBP) (Figura 4) para determinação da IG. De referir que a medida do DBP realizada no 2º ou 3º trimestres para determinar a IG apresenta uma precisão inferior à da medida da DCC no 1º trimestre, devido à maior variabilidade biológica existente no 2º e 3º trimestres. Contudo, esta medida serve ainda de referência a exames futuros de avaliação da evolução do crescimento do feto.



Figura 1.23 – Exemplo de uma imagem para medição do DBP (Imagem gentilmente cedida pelo Dr. Matos Cruz).

## 1.7 Translucência da Nuca

A medida da TN, Figura 1.24, é usada desde os anos 90 como um indicador de possíveis anomalias cromossómicas como o Síndrome de *Down* ou o Síndrome de *Turner* (Nicolaidis *et al.*, 2000). Uma medida da TN da nuca elevada é indicador de uma probabilidade/risco maior da presença deste tipo de anomalias. É, no entanto, conveniente e prudente relacionar a sua medida com o valor da DCC, pois, de uma forma geral, a TN é maior em fetos maiores e tende a aumentar com a IG, como referido anteriormente. Este método de diagnóstico revelou-se particularmente eficaz, permitindo a identificação de aproximadamente 75% dos fetos afetados, com uma taxa de falsos positivos de cerca de 5% (Nicolaidis *et al.*, 2000). A taxa de acertos aumenta para cerca de 90% (valor médio) quando as

medidas são combinadas com marcadores obtidos a partir de análise sanguínea da progenitora (Souka, Krampfl, Bakalis, Heath, & Nicolaides, 2001). Apesar de uma TN elevada não significar um cariótipo anormal, a verdade é que, mesmos nos casos em que isso não se verifica, frequentemente acaba por se constatar que o feto apresenta defeitos estruturais e síndromes genéticas (Nicolaides, 2004).




Figura 1.24 – Imagem usada para a medição da TN (Imagem gentilmente cedida pelo Dr. Matos Cruz).

## 1.8 Conclusão

Neste capítulo foram abordadas algumas das questões mais relevantes no que respeita à utilização de ultrassons na construção da imagem médica e referidas as medidas usadas no exame fetal entre as 11-13<sup>+6</sup> semanas. Os aspetos discutidos servem para evidenciar, por um lado, a importância da realização do exame durante o primeiro trimestre e, por outro, para justificar as dificuldades de tratamento das imagens ecográficas. Estas últimas apresentam baixo contraste e estão corrompidas por ruído que pode ser visualizado como presença de artefactos ou granulação da imagem, dependendo da natureza do ruído. Neste contexto a relação sinal/ruído das imagens ecográficas é reduzida, quando comparada com outros sistemas de imagiologia médica, pelo que a observação e a realização do diagnóstico dificultadas.

A responsabilidade da seleção da imagem adequada à medida e a medição propriamente dita são responsabilidade do operador. Em Portugal devem ser médicos com treino específico e devidamente certificados para o efeito por entidade idónea e pela Ordem dos Médicos a realizar estas tarefas (DGS, 2015). Apesar de estarem estabelecidas regras para a obtenção da imagem adequada a cada medida, a sua qualidade e as medidas extraídas variam de operador para operador. Mesmo na presença da mesma imagem as medidas realizadas variam. Reduzir esta variabilidade é, pois, essencial para a realização de um diagnóstico adequado. Este trabalho pretende dar um contributo neste aspeto propondo mecanismos automáticos para a extração de medidas de imagens fetais.



## 2. MEDIDAS EM ECOGRAFIAS FETAIS

### 2.1 Estado da Arte

Durante as últimas décadas, tem sido próspero o desenvolvimento de novos equipamentos de suporte ao diagnóstico médico, não sendo exceção a área da imagiologia médica. Atualmente, diferentes especialistas têm ao seu dispor uma grande variedade de instrumentos para aquisição de imagem que, combinados com algoritmos de processamento de imagem, resultam em ferramentas muito úteis na realização de diagnósticos (Dhawan, 2011). Para além dos sistemas ecográficos, refira-se o caso da Tomografia Computadorizada de Raio-X, Ressonância Magnética Nuclear, Tomografia por Emissão de Positrões, entre outros. A referida instrumentação, dependendo do seu princípio de funcionamento, pode fornecer informação mais, ou menos, detalhada sobre a condição do doente. Com base nesta informação, têm sido desenvolvidos vários trabalhos com vista à caracterização de imagens médicas, a maioria dos quais apresenta novos algoritmos ou aplica algoritmos já existentes para a segmentação e a classificação de imagens (Akay, 2009; Ibrahim, Weiss, Stuber, Spooner, & Osman, 2008; Karabatak & Ince, 2009; Worzel, Yu, Almal, & Chinnaiyan, 2009). Alguns autores realçam a particular dificuldade apresentada pelo tipo de imagens em estudo. No caso de imagens de ultrassons, a segmentação é fortemente influenciada pela qualidade dos dados que provém do sistema de aquisição. Adicionalmente, o contraste entre áreas de interesse é geralmente baixo e frequentemente existem artefactos, alguns derivam de ruído *speckle* e de anomalias na propagação do sinal, que tornam difícil conseguir realizar a segmentação da imagem (Noble & Boukerroui, 2006). Desta forma, enquanto noutras áreas da imagiologia, como por exemplo a Tomografia Computadorizada, pode ser suficiente a aplicação de métodos gerais de processamento de imagem, no caso da ultrassonografia é, frequentemente, necessário a utilização de métodos mais dirigidos que tentam modelar a física da imagem (Noble & Boukerroui, 2006). Na literatura são vários os trabalhos descritos no que respeita ao tratamento de ecografias no domínio da cardiologia, em particular para a identificação de problemas vasculares (Ibrahim *et al.*, 2008; Noble & Boukerroui, 2006; Özbay, Ceylan, & Karlik, 2006), no domínio da oncologia, na deteção de cancros (Hwang, Kim, Kang, & Park, 2007; Karabatak & Ince, 2009), na neurologia, para análise do sistema nervoso e determinação de comportamentos psicóticos (Chattopadhyay, Pratihari, & De Sarkar, 2008; Pennec, Cachier, & Ayache, 2003) e na área da ginecologia e da obstetrícia, respetivamente para examinação de ovários e para acompanhamento da

saúde materno-fetal ao longo da gestação (Chattopadhyay *et al.*, 2008; Grobbelaar & Douglas, 2007). Relativamente a esta última aplicação, são relativamente escassos os trabalhos disponíveis na literatura, podendo-se considerar serem estes em número inferior comparativamente às restantes áreas referidas (Noble & Boukerroui, 2006). Este aspeto poderá estar relacionado com a baixa qualidade muitas vezes associada às ecografias fetais, com a baixa relação sinal/ruído, assim como com a elevada variabilidade intra-classe derivada a diferenças na idade e na dinâmica do corpo dos fetos, bem como das variações dos diferentes operadores na aquisição da imagem (variabilidade inter-observador) (Carneiro *et al.*, 2008; Jardim & Figueiredo, 2005).

Como referido, para avaliação da saúde e desenvolvimento do feto, podem ser feitas diferentes medições. As mais frequentes são a medida da TN acompanhada da medida da DCC, realizadas na ecografia do primeiro trimestre. Em ecografias posteriores é frequente a medida do DBP.

Os trabalhos descritos na literatura mais recente incidem sobretudo na avaliação da TN, ao passo que os trabalhos iniciais nesta área focam medições distintas tais como DBP, a circunferência da cabeça, a circunferência abdominal e/ou o comprimento do fémur, as quais podem ser usadas para estimar a IG. Tal pode estar relacionado com o facto de, medidas como a circunferência da cabeça ou o comprimento de fémur, serem mais fáceis de obter devido ao maior contraste entre os ossos e os tecidos adjacentes (Nicolaidis, 2004). As abordagens utilizadas nos trabalhos iniciais são maioritariamente baseadas na utilização de operadores morfológicos e envolvem a deteção de contornos, estruturação de contornos e a transformada de Hough, entre outras técnicas padrão de visão por computador (Hanna & Youssef, 1997; Nicolaidis, 2004; Thomas, Jeanty, Peters, & Parrish, 1991). Utilizando imagens de ecografias de cabeças fetais, Zador *et al.*, (Zador, Salari, Chik, & Sokol, 1991) teve por objetivo a extração da elipse correspondente para medição dos eixos maior (diâmetro occipitofrontal), do eixo menor (DBP) e da circunferência da cabeça. Para tal, usou um detector de contornos baseado no gradiente da imagem que conjugou com um limiar de decisão binário. Sobre este resultado é aplicada a transformada de Hough para detectar o centro da elipse e os restantes parâmetros são obtidos pela aplicação do método dos mínimos quadrados. Os resultados obtidos na medição de 75 ecografias de cabeças fetais foram bastante próximos dos obtidos manualmente por especialistas, pelo que os autores referiram estar a recolher dados para realização de outras medições fetais, tais como DCC, fémur e abdómen. Contudo, refira-se que, com base na bibliografia recolhida, não foi possível detetar posteriores publicações, em particular no que respeita à medida DCC, para a qual se verificou a quase inexistência de trabalhos na literatura. Num estudo preliminar, Thomas *et al.*, (Thomas *et al.*, 1991), propôs-se realizar a medição do comprimento do fémur fetal para avaliação da

IG, tendo esta medida sido escolhida devido à elevada ecogenicidade dos ossos longos e pela maior facilidade em obter um modelo de uma forma essencialmente reta comparativamente a formas curvas como a cabeça fetal ou o abdómen. Para tal, o autor recorreu à utilização de operadores morfológicos uma vez que não foram obtidos bons resultados com os detetores de contornos baseados nos operadores de *Sobel* e *Kirsch*, nem com a utilização de binarizações locais ou globais. Foi utilizado um grupo de 49 ecografias digitalizadas, com e sem medição manual realizada por um especialista, e foi obtida uma elevada correlação entre as medições manuais e as realizadas pelo sistema proposto pelos autores. Contudo, o tempo referido para efetuar os cálculos necessários foi muito elevado (10 minutos), sendo considerado impraticável para utilização em prática clínica. Seguidamente, diferentes trabalhos utilizaram uma abordagem baseada em modelos de contornos ativos para a segmentação de imagens da cabeça e abdómen fetais (Chalana & Kim, 1997; Chalana, Winter, Cyr, Haynor, & Kim, 1996; Thomas *et al.*, 1991). Apesar de os resultados obtidos serem considerados como sendo bons, o sistema podia ficar retido em mínimos locais e requerer uma correção manual para permitir a convergência do algoritmo. Outra desvantagem reside na necessidade de uma intervenção inicial do operador, assinalando um ponto, pelo que estes métodos não podem ser considerados como plenamente automáticos. Chalana *et al.*, (Chalana *et al.*, 1996), sugeriu a utilização de um algoritmo de contornos ativos para a medição do DBP e circunferência da cabeça. Também esta metodologia pode ser considerada apenas como sendo semiautomática uma vez que requer que o operador especifique um ponto localizado aproximadamente no centro da cabeça, ponto a partir do qual o algoritmo deteta os limites interior e exterior do crânio do feto e que são posteriormente usados para o cálculo das medidas. O desempenho do algoritmo proposto foi avaliado num total de 35 ecografias de cabeça fetal, pela comparação de resultados com os provenientes da medição manual realizada por seis obstetras. Verificou-se que o algoritmo falhou em dois casos, contudo apresentou para os restantes casos uma elevada repetibilidade de resultados e uma elevada correlação com os valores das medições manuais. Outra desvantagem referida para este trabalho, prende-se com o tempo necessário para efetuar o cálculo (32 s), o que apesar de ser muito inferior ao descrito por Thomas *et al.* (1991), continua a ser muito elevado do ponto de vista clínico (Pathak, Chalana, & Kim, 1997).

Segundo Carneiro *et al.* (2008), apesar dos métodos atrás referidos apresentarem, de uma forma geral, bons fatores de correlação entre as medidas obtidas e as realizadas manualmente por especialistas, necessitam de modificações para que possam permitir a identificação de anatomias diferentes, demonstrando por isso uma grande falta de generalização.

Posteriormente, Jardim e Figueiredo (2005) sugeriram um novo método de segmentação de estruturas anatómicas em imagens fetais por forma a estimar e medir o contorno do fémur e secções cranianas. O contorno é estimado estatisticamente através do método de máxima verosimilhança. A função de verosimilhança compara a imagem com um contorno de referência e tenta aproximar o resultado final por um processo iterativo. A função de verosimilhança é orientada à região e para minimizar a participação do ruído na comparação são usados descritores de região de pequena ordem. Os algoritmos implementados foram testados em imagens sintetizadas com base na distribuição de Rayleigh e em 50 imagens reais. Os autores referem que a avaliação qualitativa feita por especialistas aos contornos estimados segundo o método proposto, foi considerada boa, contudo não apresentam a comparação entre resultados obtidos com esta metodologia e as medições manuais. Apesar dos autores salientarem que este método não requer o ajuste de parâmetros, uma desvantagem significativa deste trabalho é o facto de necessitar da interação do operador através da indicação de um ponto próximo da estrutura anatómica em avaliação, tornando o método apenas semiautomático. Acrescente-se o facto de este método não garantir que o algoritmo encontrará sempre a solução ótima, facto este apontado pelos próprios autores.

Lu *et al.*, (W. Lu, Tan, & Floyd, 2005), apresentou um algoritmo para deteção e medição da cabeça fetal (DBP e circunferência da cabeça) baseado na transformada de Hough aleatória iterativa. As imagens foram segmentadas por um classificador *K-means* para extração da imagem do esqueleto, o qual forneceu uma representação simples dos segmentos cranianos para deteção da cabeça do feto. Foi utilizado um pequeno conjunto de imagens (11 ecografias da cabeça fetal provenientes de 6 fetos) para teste inicial do algoritmo e um conjunto maior (206 ecografias de 96 fetos) para análise estatística, tendo-se verificado em três imagens do segundo conjunto que o resultado da aplicação da transformada de Hough aleatória não convergiu para a deteção correta. Segundo os autores, este facto pode dever-se a um baixo contraste entre o crânio e os tecidos adjacentes, assim como à existência pouco usual de grandes falhas entre os segmentos ósseos do crânio. Apesar do método proposto ser rápido (cerca de 1,6 s), não necessitar de intervenção por parte do operador, sendo assim considerado um método automático, e de o algoritmo apresentar, de uma forma geral, bons resultados, os autores referem que em alguns casos o método automático proposto pode conduzir a erros, inclusivamente pode obter elipses e medição do DBP em casos de imagens sem cabeças fetais representadas. Por este motivo, os autores referem a necessidade de desenvolver uma metodologia que permita verificar que a elipse obtida representa de facto um contorno da cabeça fetal. Mais recentemente, e ainda com o objetivo de medição da DBP para estimativa da IG, foram propostas diferentes abordagens por



Marhaban *et al.*, (Marhaban, Kaid, & Noor, 2010), e por Kolapkar & Wakankar, (Kolapkar & Wakankar, 2014). O primeiro, apresenta uma abordagem baseada no ajuste de uma curva elíptica feito pelo método dos mínimos quadrados, envolvendo três passos principais: pré-processamento da imagem, extração do objeto de interesse e ajuste à elipse da forma resultante, e medição dos parâmetros. O algoritmo proposto por Marhaban *et al.* (2010) foi desenvolvido para detecção da cabeça fetal, a qual é assumida ter uma forma elíptica. Devido à má qualidade das imagens e baixo contraste dinâmico, é aplicado um operador de aumento de contraste e um filtro de mediana seguido de um filtro passa baixo Gaussiano. O isolamento do objeto de interesse (contorno da cabeça) é obtido pela aplicação de um filtro Butterworth passa-alto. A técnica proposta foi testada num conjunto de 20 imagens de cabeças fetais, tendo sido calculada a IG com base nos valores obtidos, bem como com base nos valores de medições manuais. Apesar da excelente correlação linear entre as medidas automática vs. manual, a diferença da IG calculada com os valores obtidos por via automática variou entre 0,46 e 8,49 dias. Os autores referem que as elevadas diferenças de medição verificadas em três das imagens testadas pode ter sido devida ao baixo contraste, esbatimento/desfocagem (*blurred*), e/ou elevado ruído das imagens.

Kolapkar e Wakankar (2014) propõem um algoritmo automático baseado em operadores morfológicos e na transformada de Hough para medição do saco gestacional (SG), DBP e comprimento do fémur. O esquema implementado pelos autores inclui o pré-processamento da imagem, onde o contraste é melhorado. As imagens fetais são depois processadas através de um filtro Gaussiano e de um filtro Wiener para minimizar o ruído *speckle*, de forma a poder segmentar usando um valor de binarização global. A imagem formada pode apresentar um elevado número de falhas pelo que são usados operadores morfológicos para rejeitar falsas regiões. O contorno é detetado com operações morfológicas nos casos DBP e SG, enquanto que o comprimento do fémur é determinado pela utilização da transformada de Hough. A técnica proposta foi aplicada à análise de 7 ecografias do 1º trimestre para medição do SG, 7 ecografias do 2º trimestre para medição do DBP e 5 ecografias do 1º e 2º trimestres para medição do tamanho do fémur. Para estas três tipologias de medição, comparativamente com a medição manual, o erro foi de 0,32-4,65%, 0,4-3,66% e 0,4-3,66%, respetivamente. De referir que, comparativamente às medições referidas em trabalhos anteriores, este trabalho inclui, para além da medição da DBP e fémur, a medição do SG, o qual, apesar de não ser muito utilizado, constitui uma estrutura distinta das restantes, uma vez que não se trata de uma matriz óssea. Uma outra matriz não óssea, nomeadamente a circunferência abdominal, foi também alvo de medição no trabalho realizado por Yu *et al.* (2008), o qual pretendeu apresentar uma estratégia para

extração do contorno abdominal do feto e respetiva medida para estimativa do peso do feto, pela aplicação de uma combinação de algoritmos. Variações do perímetro abdominal refletem o grau de acumulação de gordura abdominal e a mudança global do volume de órgãos abdominais como fígado, estômago e baço. Desta forma, esta medição quando realizada na ecografia do 3º trimestre (como aconselhado pela Direção Geral de Saúde), adequa-se à avaliação do crescimento do feto, pois numa IG avançada o aumento de peso do feto deve-se sobretudo ao acumular de gordura e não ao crescimento ósseo (Jinhua Yu, Wang, & Chen, 2008). A estratégia usou um detetor de variação de contornos para detetar o contorno abdominal e aliviar os efeitos do ruído *speckle*. De seguida, aplicou um algoritmo de *clustering Fuzzy C-Means* para diferenciar as regiões do contorno do abdómen de outros contornos possivelmente pertencentes a outras estruturas. De seguida foi usada a transformada de Hough para encontrar a forma elíptica e obter uma estimativa do contorno abdominal e, por fim, uma *snake* permitiu adaptar o contorno estimado ao contorno real.

De referir que o estado-da-arte no domínio do processamento digital de imagem, com particular atenção para o caso das medidas fetais, é descrito com elevado detalhe por Yu *et al.* (2008) e por Carneiro *et al.* (2008). O primeiro autor classifica os algoritmos em várias categorias: orientado ao contorno, orientado à região, orientado ao modelo de forma, orientado a modelos deformáveis e outros métodos, apresentando as vantagens e desvantagens de cada um no que respeita ao problema que se propõe resolver (medição do perímetro abdominal, como referido). A estratégia escolhida, tal como indicado, integra os quatro tipos de técnicas de segmentação de imagem referidos, tentando retirar vantagem dos pontos fortes de cada um deles para extração do perímetro abdominal.

Carneiro *et al.* (2008) identifica as técnicas mais promissoras como sendo as seguintes: modelos de classificadores orientados ao pixel e à região, modelos de estruturas basilares, modelos de campos aleatórios de Markov, modelos baseados em aprendizagem máquina e modelos deformáveis. Para cada estratégia descreve as respetivas vantagens e desvantagens. Carneiro *et al.* (2008) propõe a utilização de uma nova estratégia hierárquica com base numa árvore de decisão suportada por *boosting* probabilístico para a obtenção de diversas medidas realizadas em ecografias fetais, nomeadamente DBP, perímetro da cabeça, perímetro abdominal, comprimento do fémur e úmero e DCC. Refira-se que, da bibliografia disponível e consultada, este trabalho é o único que propõe uma abordagem para a medição da DCC, a qual, como foi referido, é necessária à correta estimativa de risco de anomalias cromossómicas. A abordagem de Carneiro e colaboradores (2008) utiliza um conjunto base de 6 *features* que derivam da transformada *wavelet* de Haar para encontrar a sub-região retangular cujos limites estabelecem os pontos de medição. Esse conjunto de *features* é selecionado

pelo mecanismo de *boosting* nas suas múltiplas variantes: de escala, de rotação e de posição. A combinação (classificadores fortes) das várias *features* (classificadores fracos) determinada pelo *boosting* é distribuída pelos nós da árvore de decisão de forma a poder, sem retrainar, controlar a sensibilidade e a especificidade da resposta (este aspeto não é possível obter na organização comum, em cascata, do *boosting*) e de forma a acelerar a obtenção de respostas. Os autores assinalaram problemas de *overfitting*, o que os levou a utilizar uma estratégia de corte sobre a profundidade da árvore de decisão. Utiliza uma base de dados contendo um número elevado de ecografias com medições realizadas por especialistas, as quais foram utilizadas para treinar uma sequência de classificadores discriminativos. Os resultados obtidos mostraram ser superiores aos reportados por Chalana *et al.*, (Chalana *et al.*, 1996), aproximando-se, em média, dos valores obtidos por medições manuais. Os autores referem como vantagens do método proposto a sua rapidez, o facto de ser totalmente automático e permitir a utilização do mesmo algoritmo para segmentação de estruturas anatómicas diferentes, o que poderá eventualmente facilitar a extensão do sistema a outras medições fetais.

De facto, uma outra medida de sobeja importância na avaliação de anomalias cromossómicas e que tem sido referida em publicações mais recentes, consiste na medição da TN (espaço preenchido com fluido visualizado entre a zona posterior do pescoço e a pele). A maioria dos trabalhos que visa a deteção da TN necessita de intervenção humana para definição da região de interesse (Catanzariti *et al.*, 2009; Y.-H. D. Y.-H. Deng, Wang, & Chen, 2008; Y.-B. Lee, Kim, & Kim, 2007; Moratalla *et al.*, 2010; Nirmala & Palanisamy, 2009), aplicando algoritmos de segmentação e algoritmos de deteção de contornos para encontrar os segmentos que definem a TN. Com base na bibliografia disponível e consultada, o primeiro trabalho que descreve o desenvolvimento de técnicas semiautomáticas ou automáticas para a medição da TN foi realizado por Bernardino e colaboradores, (Bernardino, Cardoso, Montenegro, Bernardes, & de Sa, 1998). Neste estudo, os autores sugerem, para a marcação das linhas superiores e inferiores delimitadoras da TN, a utilização de técnicas simples: aumento de contraste pela equalização do histograma e deteção de contornos pelo operador de *Sobel*. Sobre a saída em magnitude do operador de *Sobel* é escolhido um valor limiar de binarização. O processo não consegue marcar corretamente as linhas delimitadoras em todas as imagens de teste pois a característica de gradiente usada não é específica apenas da zona de TN ao longo de várias imagens. Uma década depois, Nirmala & Palanisamy (2009), sugeriram uma estratégia baseada no algoritmo *Mean Shift* para a segmentação da região de interesse, seguida da utilização de um operador *Canny* para deteção dos limites da TN e de um detetor *Blob-Coloring* para estimar a sua espessura. Os

autores aplicaram a técnica proposta a um total de 50 ecografias de fetos com idade gestacional entre as 11 e as 14,6 semanas, contudo não apresentam comparação de resultados com os obtidos manualmente, pelo que não é possível inferir sobre o seu desempenho. Pode no entanto afirmar-se que o método apresenta a desvantagem de necessitar de intervenção humana para definição da ROI. Acrescente-se ainda que, segundo as boas práticas internacionais, não é aconselhada a realização da medição da TN em fetos após as 13<sup>+6</sup> semanas.

Um trabalho similar foi desenvolvido anteriormente por Lee *et al.*, (Y.-B. Lee *et al.*, 2007). Neste caso, os autores descrevem um método igualmente semiautomático para a medição da TN usando um filtro de difusão para melhorar o contorno, reduzindo o ruído, seguido da deteção da TN pela minimização de uma função de custo que combina a intensidade, magnitude do contorno e a continuidade da conectividade dos pixéis. O processo de otimização é resolvido por programação dinâmica. Apesar deste método apresentar resultados satisfatórios comparativamente às medições manuais, apresenta a desvantagem de ser semiautomático e de apenas poder ser aplicado quando o feto está em posição tão horizontal quanto possível.

Uma outra metodologia similar, com base nos trabalhos desenvolvidos por Bernardino *et al.* (1998) e Lee *et al.* (2007) foi proposta por Catanzariti *et al.* (2009), tratando-se igualmente de um método semiautomático. O algoritmo proposto para a deteção das duas linhas ecogénicas necessárias à medição da TN, após a identificação da ROI pelo operador, advém do seguimento do trabalho de Lee *et al.* (2007). O algoritmo proposto difere do original em vários aspetos, incluindo a utilização de uma função objetivo diferente que não está dependente do ajuste de nenhum peso combinador e na qual foi introduzido um termo que se relaciona com a obrigação do contorno ser contínuo. A distância máxima entre os limites das duas linhas ecogénicas é estimada com base na técnica referida por Bernardino *et al.* (1998). Os autores alegam que o método permite ultrapassar várias desvantagens comparativamente a métodos anteriores, resultando na obtenção de melhores resultados do que os obtidos com o método proposto por Lee *et al.* (2007). No entanto, neste trabalho não é apresentada qualquer medição da TN nem qualquer comparação com medições manuais realizadas por especialistas, tendo os autores alegado motivos técnicos para justificar a ocorrência deste facto. A utilização de outra metodologia semiautomática para medição da TN foi proposta por Moratalla *et al.* (2010). Neste método, o operador coloca uma janela ajustável sobre a área relevante para realização da medição na parte posterior do pescoço do feto. O sistema desenha então uma linha através do centro da membrana nuchal e outra linha no limite do tecido mole adjacente à coluna cervical, identificando seguidamente a distância vertical máxima entre as duas linhas. Infelizmente os autores

não fornecem detalhes sobre a implementação da metodologia utilizada, focando-se essencialmente nos resultados obtidos. O método foi testado num total de 48 imagens fetais obtidas entre as 11-13 semanas de gestação, as quais foram sujeitas a avaliação manual e pelo método semiautomático proposto, ambos realizados em duplicado e de forma aleatória, por um total de 20 especialistas. Verificou-se a obtenção de desvios padrão inferiores para as medições com o método semiautomático vs. medições manuais, quer inter-observador (0,0149 mm vs. 0,109 mm) quer intra-observador (0,05 mm vs. 0,126 mm). Os autores referem que o sistema semiautomático proposto reduz substancialmente a variabilidade da medição da TN, podendo ser uma ferramenta útil no campo da obstetria. No entanto, o sistema não evita a necessidade de fornecer a formação adequada aos operadores para que possam obter imagens corretas, sendo sempre necessário que estes inspecionem se as linhas desenhadas automaticamente pelo sistema foram ou não desenhadas corretamente antes de aceitar a medição sugerida. Para além dos métodos referidos, recentemente têm sido propostas abordagens automáticas para medição da TN. Deng *et al.*, (Y. Deng, Wang, Chen, & Yu, 2012), propõe um esquema com base num modelo hierárquico para deteção automática da região adequada à medição da TN, com vista à posterior estimativa da espessura da TN. São treinados 3 classificadores SVM, um para detectar a cabeça, outro para detetar o corpo e outro para detetar a região TN. A relação hierárquica posicional destes 3 elementos é usada para otimizar a localização da região TN pela utilização de programação dinâmica. Neste método foram utilizadas 690 ecografias, nas quais especialistas marcaram manualmente as regiões de interesse, tendo assinalado caixas delimitadoras da TN, cabeça e corpo fetal. Após treino do modelo, o objetivo consistia em avaliar se as janelas delimitadoras estimadas pelo método proposto são, ou não, colocadas nas zonas corretas (considerando-se como tal, uma sobreposição de pelo menos 50% com a área indicada pelos especialistas, caso contrário sendo considerado um falso positivo). Apesar do método apresentar bons resultados e ser automático, refira-se que apenas permite estabelecer a ROI, não realizando a medição da TN.

Neste sentido, Wee e colaboradores, (Wee, Min, Arooj, & Supriyanto, 2010), sugeriram dois patamares de processamento. No primeiro patamar, é utilizada uma rede neuronal com arquitetura *perceptron* multi-camada (MLP) com uma ou mais camadas escondidas, a qual foi treinada com 150 ecografias para reconhecimento da região de interesse (ROI) que contém a TN. No segundo patamar, servindo-se da ROI, são procurados os limites da camada TN. Os métodos convencionais de deteção de contornos, como o operador *Sobel* e o operador *Canny* detetam mais do que as duas linhas caracterizadoras da TN. Para resolver este problema, os autores desenvolveram um algoritmo que utiliza a intensidade

local, a magnitude do gradiente e a medida de continuidade conexa de pixels para otimizar a detecção das linhas de TN dentro da ROI. Nos testes realizados, o método alcançou uma precisão de 93,33% (56 de 60 imagens) no que respeita ao reconhecimento da ROI. Os autores esclareceram que nos casos onde as imagens apresentam baixo contraste e resolução o algoritmo proposto não apresenta um desempenho funcional adequado. No que respeita à comparação com os valores obtidos através de medições manuais, os valores foram similares, tendo-se obtido uma correlação elevada (0,98). Os autores apontam como limitação do método apresentado, a fraca operacionalidade em imagens de baixa qualidade, e a exigência de obtenção de ecografias com o plano correto e adequado à medição. Posteriormente, outros trabalhos têm sido desenvolvidos com vista ao desenvolvimento de abordagens que permitam a utilização de métodos automáticos para medição da TN (Anzalone *et al.*, 2013; J. H. Park, Sofka, Lee, Kim, & Zhou, 2013; Sonia, 2014). Park *et al.* (2013) propõe a utilização de um algoritmo que inicialmente deteta a posição da cabeça fetal com base em detetores baseados em aprendizagem máquina (regra de Bayes). Para tal baseia-se na aparência de estruturas características do plano médio-sagital, as quais foram previamente marcadas por especialistas em 196 imagens (marcados de forma manual 4 pontos para definição da pose da cabeça). A cabeça fetal serve depois como estrutura de referência para a detecção da pose da região que contém a TN. Esta região é depois explorada localmente e usada para definir os limites TN. Os limites internos e externos da região TN são aproximados pelo algoritmo de Dijkstra que encontra o caminho mais curto entre dois nós de um grafo. Os pesos dos nós são extraídos dos valores de magnitude do gradiente da região previamente detetada. Os limites internos e externos aproximados são usados para definir os pontos iniciadores do segmentador de mais precisão, o *graph cuts*. No final, o valor de medida TN é calculado a partir do resultado da segmentação com base na localização da sub-região de maior espessura. Para avaliação do desempenho do sistema, as 196 imagens foram divididas em dois grupos: 80% para treino e 20% (39 imagens) para teste. A existência de alguma imprecisão na detecção da localização da TN é mencionada pelos autores, a qual pode ser devida a alguma ambiguidade na localização desta região ao longo da extremidade do pescoço. Apesar dos autores referirem que o algoritmo proposto é robusto e preciso, apenas referem os valores de erro médio obtidos nos melhores e piores casos de detecção da região da TN, não detalhando resultados comparativos com medições realizadas manualmente.

Sonia and Shanthi (2014) sugerem um método para detecção e classificação direta de Síndrome de Down em ecografias da TN utilizando um sistema com base em descritores de textura de Haralick e numa SVM, consistindo em 3 fases principais: pré-processamento, extração de características e classificação. Inicialmente as imagens são pré-processadas com filtros adaptativos não-lineares, Lee e

Frost, para diminuição do ruído *speckle* e, simultaneamente, preservação dos contornos. Seguidamente, 14 características de textura são extraídas sobre uma ROI aproximada ao feto e essa região é classificada por uma SVM com função de *kernel* polinomial em classes com TN normal ou TN anormal. O sistema foi testado em dois grupos de imagens, 32 com TN normal e 39 com TN anormal, tendo sido obtida uma sensibilidade (casos normais corretamente identificados) e uma especificidade (casos anormais corretamente identificados) de 93,8 e 94,9%, respetivamente. Os autores concluem que o sistema proposto para classificação de imagens no que respeita a síndrome de Down contribui para uma classificação mais eficiente, no entanto verifica-se que no conjunto das imagens testadas, 2 imagens com TN normal foram erradamente classificadas (falsos positivos), o que pode conduzir a intervenções invasivas desnecessárias, e 10 imagens com TN anormal foram erradamente consideradas como sendo normais (falsos negativos). Este último caso é bem mais grave pois, não sendo o resultado devidamente validado pelo especialista, poderia levar à manutenção de uma gravidez anormal e, possivelmente, indesejada.

Com base nos trabalhos apresentados, podemos concluir que, independentemente da estrutura anatómica do feto a ser alvo de medição, a segmentação é uma tarefa fundamental para obtenção da medição. Ela permite separar objetos numa imagem, sendo que diferentes técnicas podem ser aplicadas para alcançar este propósito, entre as quais se incluem as estratégias descritas nos trabalhos mencionados, realizados no âmbito de medições em ecografias fetais (Suri *et al.*, 2002).

Por outro lado, a revisão apresentada, vinca as dificuldades inerentes ao processo de obtenção de medidas automáticas em imagens de sistemas baseados em ultrassons e a escassez de trabalhos que abordam a questão da medição da DCC (com exceção do trabalho de Carneiro *et al.* (2008) não foram encontrados outros trabalhos que o façam).

Neste contexto, este trabalho, pretende ser um contributo para tratar a questão da segmentação do corpo fetal com vista à obtenção da DCC, tal como referido nos objetivos.





## 3. TÉCNICAS DE FUZZY CLUSTERING

### 3.1 Introdução

As técnicas de *clustering* têm como objetivo a separação de um conjunto de dados em dois ou mais agrupamentos com base num determinado critério de similaridade. Desta forma, dados com características semelhantes (de acordo com o(s) critério(s) usado(s)) são agrupados no mesmo subconjunto (*cluster*), sendo que a união dos *clusters* formados constituem o conjunto inicial.

As metodologias de *hard clustering* são baseadas numa estrutura binária atribuindo a cada ponto um grau de pertença unitário para um determinado *cluster* e zero aos restantes. Este procedimento tende a apresentar bons resultados nos casos em que existe grande certeza nos dados, mas apresenta inconvenientes quando estes apresentam ambiguidade (e.g. resultante de ruído). Nestes casos, a matriz de partição não representa a confiança nos dados, pelo que poderão ser efetuadas atribuições erróneas.

A utilização de técnicas de *fuzzy clustering* permitem atribuir ao mesmo ponto uma pertença simultânea a dois ou mais *clusters* e, desta forma, tratar a possível ambiguidade. O resultado é uma matriz de partição que traduz a crença de um ponto pertencer a cada um dos subgrupos formados. Este valor é atribuído por uma função pertença e pode tomar um qualquer valor no intervalo  $[0,1]$ .

Diversos estudos mostram que os métodos baseados em lógica difusa aplicados ao processamento e diagnóstico de imagens médicas apresentam uma taxa de sucesso relevante (Ibrahim *et al.*, 2008; Suri *et al.*, 2002).

Neste capítulo serão apresentados alguns métodos de *Fuzzy Clustering* (FC) usados na segmentação de imagens e que foram usados neste trabalho com o objectivo de extrair das imagens fetais o corpo do feto com vista à realização da medida da DCC.

### 3.2 Fuzzy C-Means

É, provavelmente, o método de FC mais conhecido e mais aplicado na classificação dos dados. O método *Fuzzy C-Means* (FCM) (Bezdek, 1981; Bezdek, Ehrlich, & Full, 1984; Dunn, 1974), agrupa os dados nos diversos *clusters* pela minimização de uma função de custo baseada numa distância

Euclidiana. O objetivo é determinar a melhor matriz de partição,  $\mu$ , que minimiza a distância de cada ponto do espaço de características ao centro de cada *cluster*,  $c_j$ , de acordo com a Equação (3.1).

$$J_m = \sum_{j=1}^C \sum_{k=1}^N \mu_{jk}^m \|x_k - c_j\|^2 \quad (3.1)$$

$N$  representa o número de pontos,  $C$  o número de *clusters*,  $x_k$  o ponto de teste,  $c_j$  o centro do *cluster*  $j$ ,  $\mu_{jk}$  o grau de pertença do ponto  $k$  ao *cluster*  $j$ ,  $\|\cdot\|$  o operador norma euclidiana e  $m$  um fator de peso com valores no intervalo  $[1, \infty]$ . Este último permite determinar o grau de *fuzificação*, sendo que o aumento da constante contribui para o aumento da difusão da partição resultante. De uma forma geral  $m \in [1.5, 2.5]$ , sendo que na literatura a preferência recai sobre  $m = 2$  (Pal & Bezdek, 1995). A resolução da Equação (3.1) obedece às seguintes restrições:

$$0 \leq \mu_{jk} \leq 1 \quad (3.2)$$

$$0 < \sum_{k=1}^N \mu_{jk} < N, \quad \text{com } 1 \leq j \leq C \quad (3.3)$$

$$\sum_{j=1}^C \mu_{jk} = 1, \quad \text{com } 1 \leq k \leq N \quad (3.4)$$

A Equação (3.2) define que o valor do grau de pertença de cada ponto a um *cluster* terá de estar no intervalo  $[0,1]$ . A Equação (3.3) estabelece que o número de *clusters* deverá ser sempre superior a zero (na prática a solução simples não interessa, pelo que o número de *clusters* é superior a 1) e menor que o número de pontos e, por último, a Equação (3.4) define que a soma dos graus de pertença de um ponto a todos os *clusters* deverá ser igual a 1. Esta última equação pode ser vista como uma probabilidade, pelo que o método pode ser designado de *C-Means* probabilístico (de Oliveira & Pedrycz, 2007).

O processo de obtenção dos parâmetros que otimizam a função de custo  $J_m$  é do tipo NP-hard e resolvido iterativamente otimizando separadamente cada um dos parâmetros e fixando os restantes (de Oliveira & Pedrycz, 2007). Neste caso a otimização passa por encontrar, simultaneamente, os melhores centros e respetivas matrizes de partição que minimizam a distância Euclidiana. O cálculo dos centros dos *clusters* é obtido pela Equação (3.5) considerando a matriz de partição fixa e os elementos da matriz de partição pela Equação (3.6) (grau de pertença), mantendo os protótipos dos centros fixos (Bezdek, 2012; de Oliveira & Pedrycz, 2007). O processo é repetido até que a

convergência seja atingida (e.g. a variação dos coeficientes entre duas iterações consecutivas seja inferior a um determinado erro  $\varepsilon$ ). A dedução destes parâmetros é apresentada no Anexo A.

$$c_j = \frac{\sum_{k=1}^N \mu_{jk}^m x_k}{\sum_{k=1}^N \mu_{jk}^m} \quad (3.5)$$

$$\mu_{jk} = \frac{1}{\sum_{l=1}^C \left( \frac{\|x_k - c_j\|}{\|x_k - c_l\|} \right)^{\frac{2}{m-1}}} \quad (3.6)$$

O método usa, geralmente, uma inicialização aleatória dos centros dos *clusters* (ou da matriz de partição) e, com base nestes, determinada a matriz de partição (ou os centros). Apesar de o FCM derivar do método *K-means* (*hard clustering*), o resultado é mais insensível à inicialização e menos dado a convergir para mínimos locais da função de custo (Klawonn, 2005).

O método FCM pode ser eficaz na segmentação de imagens. No entanto deve-se ter em consideração dois aspetos. Em primeiro lugar o facto de, embora ao mesmo ponto possam ser atribuídas pertenças simultâneas a ambos os *clusters*, o processo de classificação exige a atribuição a um dos subgrupos. De uma forma geral a tomada de decisão baseia-se no valor máximo de pertença ao *cluster*. Por outro lado, a atribuição dos pixels aos respetivos *clusters* é baseada apenas na distribuição dos atributos no espaço de características, no caso a intensidade. Neste contexto, uma das desvantagens do método FCM prende-se com o facto de apenas incorporar na função de custo os aspetos referentes à própria intensidade (espaço de características usado). A otimização da matriz de partição é realizada tendo unicamente como critério a distância Euclidiana entre a intensidade (ou outra característica usada) de cada pixel e o centro do *cluster* o que, no caso da existência de ruído, pode resultar em classificações indesejadas e contribui para a falta de robustez do método.

Uma das formas de minimizar este efeito consiste em incorporar na decisão informação espacial, para que a tomada de decisão seja realizada com base não apenas na intensidade do ponto mas também na sua vizinhança.

### 3.3 Limite de Decisão Baseado na Vizinhança

Atendendo ao que foi referido foi implementado um esquema de decisão simples baseado na vizinhança. Obtida a partição pelo método FCM, a decisão de atribuir cada ponto ao respetivo *cluster*

depende dos graus de pertença dos pixéis vizinhos a cada *cluster*. Desta forma a decisão de incluir um determinado ponto num *cluster* depende das características dos pixéis vizinhos. Neste contexto é criada uma nova matriz de partição, baseada na partição inicial do FCM, resultado da média dos graus de pertença dos pixéis vizinhos numa determinada janela. O resultado não é mais do que a partição FCM filtrada por um filtro de média de acordo com a Equação (3.7).

$$\mu_{jk} = \frac{1}{N_i} \sum_{i=1}^{N_i} \mu_{ji} \quad (3.7)$$

Na Equação (3.7)  $N_i$  representa o número de pontos da janela,  $k$  o pixel central e  $\mu_{jk}$  o grau de pertença do ponto  $k$  ao cluster  $j$ .

Este método será referido ao longo deste trabalho por FCMV.

### 3.4 Fuzzy C-means com Informação Espacial

Tal como referido, o FCM usa a otimização da distância (no espaço de características que, geralmente, corresponde à intensidade) para agregar os dados no respetivo *cluster*. No entanto, é sabido que os pixéis vizinhos possuem uma correlação elevada, pelo que a probabilidade de pixéis próximos possuírem características semelhantes é alta. A inclusão da informação espacial no processo de decisão pode contribuir para a melhoria do resultado da segmentação. Na secção 3.3 este procedimento foi realizado *a posteriori* do processo de *clustering*. De seguida apresenta-se a aplicação de métodos de *fuzzy clustering* que incluem a informação espacial durante o processo de otimização. O resultado é uma matriz de partição que, simultaneamente, depende da distância do ponto ao espaço de características e das características dos pixéis vizinhos.

#### 3.4.1 FCMS<sub>1</sub>

Chuang *et al.*, (Chuang, Tzeng, Chen, Wu, & Chen, 2006), propõem um método para incluir a informação espacial no processo de construção da matriz de partição baseado no FCM. O método consiste em, a partir da partição clássica do FCM, construir uma matriz de partição espacial,  $h_{jk}$ , de acordo com a Equação (3.8):

$$h_{jk} = \sum_{i \in V_{x_k}} \mu_{ji} \quad (3.8)$$

onde  $V_{x_k}$  representa o conjunto de pontos na vizinhança de  $x_k$ ,  $k$  o pixel central,  $j$  o *cluster* e  $\mu_{ji}$  representa a função pertença do método FCM normal. A função de partição espacial é depois usada para recalculer a matriz de partição difusa de acordo com a Equação (3.9):

$$\hat{\mu}_{jk} = \frac{\mu_{jk}^p h_{jk}^q}{\sum_{i=1}^C \mu_{ik}^p h_{ik}^q} \quad (3.9)$$

onde  $p$  e  $q$  são dois parâmetros ajustáveis que permitem regular a contribuição de cada componente que interfere na partição. Note-se que se  $p = 1$  e  $q = 0$  então o método recai no FCM clássico. Em cada iteração é usada a última partição realizada ( $\hat{\mu}_{jk}$ ) pelo método normal FCM para recalculer os centros.

O método, doravante designado por FCMS<sub>1</sub>, tem a vantagem de em regiões homogêneas a função espacial ajudar a reforçar a função pertença original (resultado do FCM), pelo que a classificação desses pontos não sairá alterada. Nos casos de existirem pixéis com ruído, o método permite ajustar a sua partição com os pixéis vizinhos (aos quais se pressupõe elevada correlação) e, portanto, reduzir os pixéis mal classificados (Chuang *et al.*, 2006).

### 3.4.2 FCMS<sub>2</sub> e FCMS<sub>2m</sub>

Existem outras abordagens no processo de segmentação baseado no método FCM com inclusão de informação espacial. Trabalhos como (Ahmed, Yamany, Mohamed, Farag, & Moriarty, 2002; Cai, Chen, & Zhang, 2007; S. C. Chen & Zhang, 2004; L. Szilagyi, Benyo, Szilagyi, & Adam, 2003) propõem alternativas ao método referido. Ahmed *et al.*, (Ahmed *et al.*, 2002), introduz na função de custo um termo que permite um determinado pixel ser condicionado pelos vizinhos. A função objetivo modificada é dada pela Equação (3.10).

$$J_m = \sum_{j=1}^C \sum_{k=1}^N \mu_{jk}^m \|x_k - c_j\|^2 + \frac{\alpha}{N_R} \sum_{j=1}^C \sum_{k=1}^N \mu_{jk}^m \sum_{r \in N_k} \|x_r - c_j\|^2 \quad (3.10)$$

$x_r$  representa os pixéis na vizinhança do pixel  $x_k$ ,  $N_k$  o conjunto dos pixéis vizinhos e  $N_R$  a cardinalidade de  $N_k$ . O parâmetro  $\alpha$  é usado para controlar a contribuição da vizinhança na otimização. A otimização passa por encontrar a partição,  $\mu_{jk}$ , e os centros,  $c_j$ , que minimizam  $J_m$ , de acordo com as equações (3.11) e (3.12). Note-se que na Equação (3.12) o termo  $\sum_{r \in N_k} x_r / N_R$

representa a média das intensidades em torno de  $k$ , pelo que o termo pode ser visto como a imagem original filtrada (filtro de média).

$$\mu_{jk} = \frac{\left( \|x_k - c_j\|^2 + \frac{\alpha}{N_R} \sum_{r \in N_k} \|x_r - c_j\|^2 \right)^{\frac{-1}{m-1}}}{\sum_{i=1}^C \left( \|x_k - c_i\|^2 + \frac{\alpha}{N_R} \sum_{r \in N_k} \|x_r - c_i\|^2 \right)^{\frac{-1}{m-1}}} \quad (3.11)$$

$$c_j = \frac{\sum_{k=1}^N \mu_{jk}^m \left( x_k + \frac{\alpha}{N_R} \sum_{r \in N_k} x_r \right)}{(1 + \alpha) \sum_{k=1}^N \mu_{jk}^m} \quad (3.12)$$

Chen & Zhang, (S. C. Chen & Zhang, 2004), propõem uma variante do método referido que consiste em substituir o termo espacial da função de custo por:

$$J_m = \sum_{j=1}^C \sum_{k=1}^N \mu_{jk}^m \|x_k - c_j\|^2 + \alpha \sum_{j=1}^C \sum_{k=1}^N \mu_{jk}^m \|\bar{x}_k - c_j\|^2 \quad (3.13)$$

onde  $\bar{x}_k$  representa a média dos pixéis vizinhos de  $x_k$  para uma determinada janela. A minimização de  $J_m$  passa por encontrar:

$$\mu_{jk} = \frac{\left( \|x_k - c_j\|^2 + \alpha \|\bar{x}_k - c_j\|^2 \right)^{\frac{-1}{m-1}}}{\sum_{i=1}^C \left( \|x_k - c_i\|^2 + \alpha \|\bar{x}_k - c_i\|^2 \right)^{\frac{-1}{m-1}}} \quad (3.14)$$

$$c_j = \frac{\sum_{k=1}^N \mu_{jk}^m (x_k + \alpha \bar{x}_k)}{(1 + \alpha) \sum_{k=1}^N \mu_{jk}^m} \quad (3.15)$$

Esta alteração, acima de tudo, permite reduzir o tempo de execução e melhorar a robustez ao ruído do tipo Gaussiano (S. C. Chen & Zhang, 2004). Este método será designado por FCMS<sub>2</sub>.

O método apresenta, no entanto, limitações quando as imagens se encontram contaminadas com ruído não Gaussiano, como por exemplo ruído impulsional como “*salt and pepper*” (S. C. Chen & Zhang, 2004). Nestes casos os autores sugerem a utilização de um filtro alternativo que melhore a robustez do classificador (e.g. substituir a média pela mediana). O método alterado para o filtro mediana será designado por FCMS<sub>2m</sub>.

Relembre-se, neste ponto, que, de uma forma geral, as imagens de ultrassons são afetadas essencialmente por um outro tipo de ruído, designado por *speckle*. Neste contexto, a utilização do filtro de média ou de mediana não contribuirá para uma melhoria significativa do resultado da segmentação. Tendencialmente, os métodos referidos são usados na segmentação de imagens de Ressonância Magnética com bons resultados onde os efeitos do ruído são menos dramáticos na deterioração da qualidade das imagens (S. C. Chen & Zhang, 2004; L. Szilagyi *et al.*, 2003; J. Wang, Kong, Lu, Qi, & Zhang, 2008).

Tal como referido,  $\alpha$  permite realizar o ajuste da influência da componente espacial no resultado da classificação. O seu ajuste depende de um equilíbrio entre a robustez ao ruído e eficiência na preservação do detalhe da imagem e traduz-se na prática numa seleção por tentativa e erro (Cai *et al.*, 2007). Por um lado um valor elevado pode contribuir para a eliminação de pixéis corrompidos por ruído mas contribuirá também para a perda de detalhe (um pouco como a própria largura da janela usada). Por outro, o uso de um valor baixo é vantajoso para pixéis não corrompidos. Este compromisso nem sempre é simples de alcançar e exige algum esforço computacional.

### 3.4.3 FCMS<sub>3</sub>

Na tentativa de corrigir estas dificuldades Cai *et al.* (Cai *et al.*, 2007) propõem um método (aqui designado por FCMS<sub>3</sub>) que elimina a necessidade do ajuste do parâmetro  $\alpha$ . Para tal introduzem uma medida de similaridade da imagem que incorpora, simultaneamente, a informação espacial e de relação de intensidade locais. A métrica usada é dada pela Equação (3.16).

$$S_{ij} = S_{ij}^S \times S_{ij}^G \quad (3.16)$$

Na equação anterior,  $i$  representa o pixel central e  $j$  os pixéis vizinhos (dentro da janela usada). No caso de  $i = j$  então  $S_{ij} = 0$ .  $S_{ij}^S$  estabelece a relação espacial local e é calculada pela Equação (3.17).

$S_{ij}^G$  reflete as relações de intensidade (níveis de cinzento) e é calculada pela Equação (3.18).

$$S_{ij}^S = \exp\left(\frac{-\max(|x_j - x_i|, |y_j - y_i|)}{\lambda_s}\right) \quad (3.17)$$

$$S_{ij}^G = \exp\left(\frac{-\|g_i - g_j\|^2}{\lambda_g \times \sigma_{G_i}^2}\right) \quad (3.18)$$

Na Equação (3.17)  $\max(\cdot)$  representa a função máximo e o par  $(x, y)$  as coordenadas espaciais do ponto ( $i$  o ponto central e  $j$  os pontos vizinhos).  $\lambda_s$  determina o espalhamento de  $S_{ij}^s$ , permitindo ajustar o peso da influência dos pontos vizinhos em função da distância ao ponto central. Relativamente à Equação (3.18),  $g_i$  representa a intensidade do pixel central e  $g_j$  dos pixels vizinhos contidos pela janela usada.  $\lambda_G$  determina o fator de escala do espalhamento de  $S_{ij}^G$  e  $\sigma_{G_i}$  é calculado pela Equação (3.19).

$$\sigma_{G_i} = \sqrt{\frac{\sum_{j \in N_i} \|g_j - g_i\|^2}{N_R}} \quad (3.19)$$

O valor de  $\sigma_{G_i}$  depende da densidade dos pixels envolventes ao pixel central e reflete a homogeneidade da janela local (Cai *et al.*, 2007). Quanto menor o seu valor mais homogênea é a janela local. A partir da medida de similaridade definida pela Equação (3.16) é possível criar uma nova imagem:

$$\xi_i = \frac{\sum_{j \in N_i} S_{ij} g_j}{\sum_{j \in N_i} S_{ij}} \quad (3.20)$$

Na Equação (3.20),  $\xi_i$  representa o novo valor do pixel (intensidade),  $g_j$  representa a intensidade dos pixels vizinhos ao pixel  $i$  na janela  $N_i$  (conjunto dos pixels vizinhos ao pixel central).

O resultado é uma imagem,  $\xi_i$ , que estabelece pesos distintos da influência dos pixels vizinhos no pixel central em função da distância espacial e em função da diferença de intensidade de cada pixel vizinho relativamente ao pixel central.  $S_{ij}$  pode ser vista como o peso do pixel  $j$  e  $\xi_i$  como o pixel  $i$  resultado da soma linearmente pesada da imagem (Cai *et al.*, 2007).

Esta nova imagem é integrada no processo de segmentação por inclusão na função a minimizar:

$$J_m = \sum_{j=1}^C \sum_{l=1}^Q \gamma_l \mu_{jl}^m (\xi_l - c_j)^2 \quad (3.21)$$

onde  $\gamma_l$  representa o número de pontos com o mesmo nível de intensidade que o pixel  $l$  e  $Q$  o número total de tons de cinzento que compõem a nova imagem. Este mecanismo de utilização do número de tons de cinzento é uma derivação do trabalho proposto por Szilágyi *et al.* (L. Szilagyi *et al.*, 2003) e permite reduzir o esforço computacional exigido no processo de otimização. De uma forma geral  $Q$  é quase sempre menor que o número total de pontos que constituem a imagem.



A minimização da função de custo (Equação (3.21)) é encontrada iterativamente calculando a matriz de partição,  $\mu$ , e os respectivos centros,  $c$ , pelas equações (3.22) e (3.23), respetivamente.

$$\mu_{jl} = \frac{(\xi_l - c_j)^{-\frac{2}{m-1}}}{\sum_{j=1}^C (\xi_l - c_j)^{-\frac{2}{m-1}}} \quad (3.22)$$

$$c_j = \frac{\sum_{l=1}^Q \gamma_l \mu_{jl}^m \xi_l}{\sum_{l=1}^Q \gamma_l \mu_{jl}^m} \quad (3.23)$$

#### 3.4.4 GKFCM

Os métodos de FC baseados em *kernels gaussianos* (GKFCM) têm apresentado bons resultados na segmentação de imagens de ultrassons (S. C. Chen & Zhang, 2004; Gupta, Anand, & Tyagi, 2015). Estes métodos apresentam, na sua essência, ideias semelhantes aos propostos nos métodos anteriores tentando realizar a ação de *clustering* com correção espacial. As diferenças principais residem na utilização de um *kernel* (Gaussiano) em substituição da medida habitual da distância Euclidiana que permite melhorar a robustez do sistema ao ruído e *outliers*. A função de custo associada é dada pela Equação (3.24).

$$J_m = \sum_{j=1}^C \sum_{k=1}^N \mu_{jk}^m (1 - K(x_k, c_j)) + \sum_{j=1}^C \sum_{k=1}^N \eta_j \mu_{jk}^m (1 - K(X, c_j)) \quad (3.24)$$

Onde  $K(x, c)$  representa o *kernel* usado no mapeamento dos dados para o espaço de características e  $X$  representa a média ou mediana dos pixéis vizinhos a  $x_k$  numa determinada vizinhança. O *kernel* usado é representado pela Equação (3.25).

$$K(x_k, c_j) = \exp\left(-\frac{\|x_k - c_j\|^2}{\sigma^2}\right) \quad (3.25)$$

com  $\sigma^2 = \frac{1}{N} \sum_{k=1}^N \left\| x_k - \frac{1}{N} \sum_{k=1}^N x_k \right\|^2$ . Esta variável permite controlar a dispersão do *gaussiano*, pelo que a medida mais usada é a variância.

O método apresenta ainda a particularidade de poder usar valores distintos no controlo do efeito da vizinhança em cada *cluster* através de  $\eta_j$ . O valor é calculado iterativamente pela Equação (3.26):

$$\eta_j = \frac{\min_{j' \neq j} (1 - K(c_{j'}, c_j))}{\max_i (1 - K(c_i, M))} \quad (3.26)$$

$$\text{com } M = \frac{1}{N} \sum_{k=1}^N x_k.$$

Os pesos  $\eta_j$  são calculados pelo quociente entre duas distâncias suavizadas por um *gaussiano*. O numerador fornece a separação do conjunto de dados para o cluster  $j$ . Se o valor mínimo da distância do *cluster*  $j$  aos restantes *clusters* é elevado, então, essa classe encontra-se isolada, pelo que o valor de  $\eta_j$  deve ser elevado. O denominador fornece uma medida de separação total e funciona como termo normalizador. O quociente pode ser usado como uma medida de separação normalizada (Yang & Tsai, 2008).

O processo de otimização é realizado iterativamente até que a função de custo alcance o valor desejado por cálculo alternado de:

$$\mu_{jk} = \frac{1}{\sum_{i=1}^C \left( \frac{(1 - K(x_k, c_j)) + \eta_j (1 - K(X, c_j))}{(1 - K(x_k, c_i)) + \eta_j (1 - K(X, c_i))} \right)^{\frac{1}{m-1}}} \quad (3.27)$$

$$c_j = \frac{\sum_{k=1}^N \mu_{jk}^m (K(x_k, c_j) x_k + \eta_j K(X, c_j) X)}{\sum_{k=1}^N \mu_{jk}^m (K(x_k, c_j) + \eta_j K(X, c_j))} \quad (3.28)$$

GKFCM assemelha-se ao método FCMS<sub>2</sub> (FCMS<sub>2m</sub>). Tem, no entanto, a vantagem de usar pesos distintos para cada uma das classes e de os poder ajustar durante o processo de otimização. Por outro lado, a medida da distância dos centros aos pontos e dos centros à imagem filtrada (as duas componentes que compõem a função de custo) é realizada através de um *gaussiano*, o que permite melhorar o comportamento do classificador em imagens com ruído. Para além da versão com filtro de média foi testada uma versão com filtro de mediana, referida neste documento por GKFCM<sub>m</sub>.

### 3.5 Validação da Segmentação

Um dos problemas que se colocam após o *clustering* é a validação dos grupos (*clusters*) resultantes. A validação permite aferir a crença na partição resultante (Pal & Bezdek, 1995) e serve para avaliar o desempenho e robustez do classificador. Os primeiros coeficientes de validação foram propostos por

Bezdek *et al.* (Bezdek, 1973; 1975) e permitem avaliar o resultado da partição através do cálculo do Coeficiente da Partição (CP) e da Entropia da Partição (EP), respetivamente representados pelas equações (3.29) e (3.30).

$$CP = \frac{1}{N} \sum_{k=1}^N \sum_{j=1}^C \mu_{jk}^2 \quad (3.29)$$

$$EP = -\frac{1}{N} \sum_{k=1}^N \sum_{j=1}^C (\mu_{jk} \log \mu_{jk}) \quad (3.30)$$

$N$  representa o número de pontos,  $C$  o número de *clusters* e  $\mu_{jk}$  o grau de pertença do ponto  $k$  ao *cluster*  $j$ . Esta mesma notação será usada para os índices seguintes.

A ideia subjacente à utilização das duas funções anteriores é a de que uma partição pouco difusa é melhor que uma com elevado índice de difusão. Usando esta métrica, uma boa segmentação (*clustering*) será alcançada quando  $CP$  for máximo e/ou  $EP$  mínimo.

Uma das desvantagens destes coeficientes é que apenas consideram o resultado da partição, pelo que não estabelecem qualquer relação com o espaço de características (Chuang *et al.*, 2006). Um índice que tem em consideração a estrutura geométrica dos dados foi proposto por Fukuyama e Sugeno, (Fukuyama & Sugeno, 1989), e está expresso na Equação (3.31).

$$FS = \sum_{j=1}^C \sum_{k=1}^N \mu_{jk}^m \|x_k - c_j\|^2 - \sum_{j=1}^C \sum_{k=1}^N \mu_{jk}^m \|c_j - \bar{c}\|^2 \quad (3.31)$$

O primeiro termo da função mede a compactação e o segundo a dispersão ou separação da partição.

Na equação anterior  $\bar{c} = \frac{1}{C} \sum_{j=1}^C c_j$ . O melhor resultado é obtido para  $FS$  máximo.

Outro índice que tem em linha de conta a relação com os dados é o Xie e Beni, (Xie & Beni, 1991). A função de validação é definida pela Equação (3.32).

$$XB = \frac{\sum_{j=1}^C \sum_{k=1}^N \mu_{jk}^2 \|x_k - c_j\|^2}{N * \left( \min_{j \neq i} \left\{ \|c_i - c_j\|^2 \right\} \right)} \quad (3.32)$$

Um valor baixo de  $XB$  é um indicador de uma boa segmentação.

Um terceiro índice que permite considerar a relação com os dados é o proposto por Gath e Geva, (Gath & Gev, 1989). O coeficiente de validação é calculado pela Equação (3.33).

$$GG = \sum_{j=1}^C \left[ \det(F_j) \right]^{1/2} \quad (3.33)$$

$$F_j = \frac{\sum_{k=1}^N \mu_{jk}^m (x_k - c_j)(x_k - c_j)^T}{\sum_{k=1}^N \mu_{jk}^m} \quad (3.34)$$

A Equação (3.34) representa a matriz de covariância difusa do *cluster*  $j$ . Quanto menor for o valor de  $GG$  melhor será o resultado da segmentação pois significa que a partição é mais estreita.

Apesar de na literatura existirem diversos índices de validação, (Bezdek, 2012; Gath & Gev, 1989; Pal & Bezdek, 1995; B. Rezaee, 2010; M. R. Rezaee, Lelieveldt, & Reiber, 1998; Valente, Braga, & Pedrycz, 2013; W. Wang & Zhang, 2007; K. L. Wu & Yang, 2005; Xie & Beni, 1991), estes foram selecionados por abrangerem os dois tipos principais de validação - baseados apenas na partição e baseados na partição e na estrutura dos dados - e por serem os mais referenciados.

É importante referir que, apesar de estes métodos serem indicadores da qualidade da partição, não garantem que o resultado seja ótimo. Eles são apenas uma métrica que permite avaliar o resultado da partição em função da compactação e/ou separação. Uma partição ótima apresenta uma compactação máxima para cada *cluster* de forma a que estes se encontrem a uma distância máxima. Por outro lado, se atendermos apenas à separação entre os *clusters*, a melhor partição será aquela cuja distância entre o conjunto dos pontos que o integram e o *cluster* é mínima (M. R. Rezaee *et al.*, 1998).

Uma outra forma de realizar a validação da segmentação é através da análise da sua exatidão. Para a realização desta medida é fundamental o conhecimento prévio da segmentação ótima ou, dito de outra forma, o conhecimento dos pixels que pertencem a cada *cluster*. A Exatidão da Segmentação (ES) pode então ser vista como o número total de pixels corretamente classificados relativamente ao número total de pixels da imagem tal como indicado na Equação (3.35).

$$ES = \frac{1}{N} \sum_{j=1}^C \sum_{k=1}^N e_k \quad (3.35)$$

Na equação anterior  $e_k = 1$  se o pixel  $k$  foi bem classificado e  $e_k = 0$  se incorretamente classificado. Considerou-se um pixel bem classificado aquele cujo grau de pertença máximo, resultado da partição, corresponde ao mesmo *cluster* definido pela segmentação “ótima”, obtida por manipulação manual das imagens de referência. Na situação ideal  $ES = 1$ .

Os resultados da validação são apresentados e discutidos no Capítulo 6.

### 3.6 Conclusão

Neste capítulo foram apresentados alguns dos métodos de FC habitualmente usados. Foi introduzido o método clássico FCM e algumas derivações que permitem incluir no processo de *clustering* informação espacial local (para além da informação usual do espaço de características) e melhorar o seu comportamento perante a presença de ruído, tornando o classificador mais robusto e eficiente.

As técnicas são referidas na literatura como sendo particularmente eficazes na segmentação de imagens médicas. No entanto, quando usadas neste contexto, são habitualmente aplicadas a imagens de ressonância magnética, imagens ecográficas cardiovasculares ou imagens sintetizadas com características muito próprias. As aplicações a imagens ecográficas fetais são escassas pelo que a sua utilização no contexto deste trabalho pode representar um contributo importante para a avaliação do seu desempenho. Por outro lado, os bons resultados apresentados no tratamento de imagens com ruído constitui uma propriedade importante que justifica a sua utilização no processamento de imagens ecográficas.

Foram ainda apresentados os coeficientes de validação mais comuns de análise do resultado da partição difusa. Estes índices permitem avaliar o desempenho do classificador analisando a compactação da partição e a separação dos *clusters* resultantes. Para complementar estas funções de validação foi também introduzido o coeficiente de avaliação da exatidão da segmentação, ES, que permite validar por confrontação com uma segmentação manual, considerada ótima, o resultado de cada um dos métodos de FC sugeridos.

Os métodos de FC foram aplicados às imagens fetais entre as 11-14 semanas e validados com recurso aos coeficientes referidos. Os resultados da segmentação e da validação são apresentados e discutidos no Capítulo 6.



## 4. CONTORNOS ATIVOS E *LEVEL SETS*

### 4.1 Introdução

Os contornos ativos, modelos deformáveis ou modelos ativos representam uma classe de modelos que permitem evoluir uma curva ou um contorno inicial para uma região que corresponda ao limite de um ou mais objetos. A evolução depende de um conjunto de forças, de natureza interna ou externa, e são formuladas sob a forma de uma função de custo a minimizar. Na literatura é frequente encontrarmos duas abordagens distintas na implementação destes métodos. A primeira utiliza a caracterização paramétrica da curva, definida por um conjunto de pontos da imagem, e a evolução é realizada de acordo com a função de evolução através do cálculo das novas posições de cada ponto resultado da função evolutiva. Os pontos são tratados como partículas e a evolução do contorno é realizado partícula a partícula de acordo com uma função de controlo, geralmente designada por velocidade. Este tipo de metodologias requer elevado esforço computacional e cuidados adicionais para tratar variações topológicas como cruzamentos ou separações da curva. A segunda versão utiliza uma definição implícita da curva, embebendo o contorno numa função de dimensão superior que permite tratar a curva como sendo o *Level Set* (LS) zero de uma superfície. Esta abordagem, paradoxalmente, permite reduzir o esforço computacional para realizar a evolução da curva sem comprometer os resultados.

Este capítulo apresenta uma secção inicial com a descrição de um método de contornos ativos, designado por *snake*. De seguida são apresentados os métodos de caracterização e evolução de uma curva na forma implícita. Na secção final é apresentado um método de contornos ativos, baseado numa implementação implícita que apresenta bons resultados na segmentação de imagens médicas. Ao contrário da grande maioria dos métodos de contornos ativos ou modelos deformáveis, o método apresentado, designado por Chan-Vese em homenagem aos seus criadores, não recorre ao gradiente da imagem para realizar a evolução da curva para a região de menor energia (calculada pelo funcional usado), pelo que é mais insensível ao ruído e, como tal, indicado para se aplicar neste trabalho.

## 4.2 Contornos Ativos

Os contornos ativos, também designados por *snakes*, representam um conjunto de métodos que permitem evoluir uma curva por forma a encontrar um estado estacionário na imagem que, de uma forma geral, corresponde às regiões com gradiente elevado. Desta forma, uma *snake*, é uma curva guiada por um conjunto de forças que a fazem convergir para regiões delimitadoras de um objeto (*edges*) através da minimização de uma função de custo (Kass, Witkin, & Terzopoulos, 1988).

De acordo com a formulação inicial fornecida por (Kass *et al.*, 1988) o funcional a minimizar consiste em:

$$E = \int_0^1 E_i(C(s)) + E_{img}(C(s)) + E_c(C(s)) ds \quad (4.1)$$

Na Equação (4.1),  $C(s) = (x(s), y(s))$  representa a curva parametrizada com  $s \in [0, 1]$ ,  $E_i$  representa a energia interna da curva,  $E_{img}$  forças da própria imagem que se relacionam com características extraídas da mesma e  $E_c$  forças externas que permitem interagir com a curva. No trabalho original,  $E_c$  toma a forma da força associada a uma mola, do tipo  $-k(x_1 - x_2)$ , em que  $x_1$  e  $x_2$  representam os pontos em que a mola se encontra conectada (um deles coincide com a própria curva). Esta última componente não foi usada neste trabalho.

Cada um dos restantes termos referidos é dado por:

$$E_i = \frac{\alpha(s) |C_s(s)|^2 + \beta(s) |C_{ss}(s)|^2}{2} \quad (4.2)$$

$$E_{img} = \omega_l E_l + \omega_e E_e + \omega_t E_t \quad (4.3)$$

$$E_l = I(x, y) \quad (4.4)$$

$$E_e = -(G_\sigma * \nabla^2 I)^2 \quad (4.5)$$

$$E_t = \frac{C_{yy} C_x^2 - 2C_{xy} C_x C_y + C_{xx} C_y^2}{(C_x^2 + C_y^2)^{3/2}} \quad (4.6)$$

Nas equações anteriores  $\alpha(s)$  e  $\beta(s)$  são pesos que permitem controlar a importância relativa de cada termo associado, sendo que  $C_s(s) = \frac{\partial C}{\partial s}$  e  $C_{ss}(s) = \frac{\partial^2 C}{\partial s^2}$ ,  $\omega_l$ ,  $\omega_e$  e  $\omega_t$  os pesos associados aos termos que compõem a energia da imagem, com  $I(x, y)$  a própria imagem (vista em termos de intensidade),  $G_\sigma$  representa um Gaussiano, e  $E_t$  a função referente às terminações. A Equação (4.4)



permite atrair a *snake* para linhas claras ou escuras, dependendo do sinal do peso associado. Por outro lado, as equações (4.5) e (4.6) permitem guiar a *snake* de encontro a *edges* ou terminações, respetivamente (Kass *et al.*, 1988).

Note-se que na Equação (4.5) não é usado o gradiente da imagem original. Em vez disso, é usada uma versão filtrada através de um Gaussiano e que permite suavizar as regiões delimitadoras e reduzir os efeitos do ruído. Este mesmo procedimento pode ser realizado na Equação (4.4), pelo que  $E_i = G_\sigma * I(x, y)$  ou outra versão filtrada da imagem  $I$ .

De forma resumida o modelo introduzido em (4.1) pode ser visto como o resultado de duas componentes. Uma primeira que controla a suavidade da curva, dada por  $E_i$ , e uma segunda componente que permite atrair a curva para os pontos de interesse e que na generalidade dos casos é fornecida por um detetor de contornos semelhante ao representado na Equação (4.5). Portanto, o resultado é a evolução ou propagação de uma curva, fornecido por uma aproximação inicial, controlada em termos de forma em direção às regiões de maior gradiente.

As *snakes* descritas não garantem, apesar de tudo, a convergência para mínimos globais. Por outro lado, a solução minimizante não é invariante à parametrização, pelo que resultados distintos podem ser obtidos pela alteração da parametrização. Outro aspeto relevante é a limitação do número de objetos possíveis de identificar. Dado que o método não consegue lidar com as variações topológicas, é impossível detetar mais que um objeto (e esse objeto deverá ser convexo) (Aubert & Kornprobst, 2008).

De seguida serão discutidas as metodologias que contribuem para a resolução destes problemas.

### 4.3 Level Sets

Os contornos ativos requerem a implementação de mecanismos de propagação de curvas. Um dos métodos que teve grande impacto neste domínio, designadamente ao nível do processamento de imagem, são os *Level Sets* (LS) (Osher & Sethian, 1988).

Uma curva  $C(p) = (x(p), y(p))$ , parametrizada por  $p$ , pode ser vista como o conjunto de pontos que a compõem e, que na prática, é representada pelas coordenadas dos respetivos pontos. Esta é uma forma explícita de a representar que exige algum esforço computacional (quer no que se refere a memória quer ao esforço computacional para a implementação da sua evolução). No entanto, esta não é a única forma de a reproduzir. De facto, existe a possibilidade de a definir implicitamente através da definição do conjunto de pontos que obedecem a uma determinada condição. Deste modo a curva

pode ser definida como  $C = \{(x,y) | \phi(x,y) = 0\}$ , em que  $\phi$  representa a Função *Level Set* (FLS). A FLS pode ser vista como uma função de nível para a qual qualquer ponto  $(x,y)$  no interior da curva apresenta um valor positivo e um ponto no exterior um valor negativo (Figura 4.1). Desta forma a curva propriamente dita é formada pelos pontos cuja distância é nula, ou dito de outra forma, pelos pontos para os quais  $\phi(x,y) = 0$  (também designada por *Level Set zero*). O método tem a particularidade de não necessitar conhecer explicitamente os pontos que constituem a curva pois estes serão sempre encontrados pela resolução da equação  $\phi(x,y) = 0$ . É, no entanto, necessário conhecer a FLS.

A utilização da FLS implica um aumento na dimensionalidade do problema. No caso de uma imagem a FLS tem uma dimensão adicional, sendo representada por uma superfície. No entanto, os benefícios superam largamente esta desvantagem.




Figura 4.1 – A curva vista como o *Level Set* zero de uma superfície (FLS).

Numa representação paramétrica a evolução da curva corresponde a calcular os pontos da curva tal que:

$$\frac{dC}{dt} = V\vec{N} \quad (4.7)$$

onde  $V$  representa a velocidade (função de controlo da evolução da curva) e  $\vec{N}$  a normal à curva no ponto.

Numa abordagem LS, prova-se que a evolução da curva é determinada pela evolução do LS zero ao longo do tempo,  $\phi(t,x,y) = 0$ , e pode ser aproximada pela Equação (4.8).

$$\frac{d\phi}{dt} = V|\nabla\phi| \quad (4.8)$$

Desde que  $V$  esteja bem definida em todo o domínio a equação diferencial parcial anterior tem solução, pelo que a curva pode ser extraída a partir do LS zero de  $\phi$ .

O modelo final considera ainda que  $\frac{\partial \phi}{\partial N} = 0$  em  $\partial \Omega$  (o contorno) (com  $(x, y) \in \Omega$ ) e que

$\phi(0, x, y) = d((x, y), c_0)$ , sendo que  $d$  representa a distância Euclidiana do ponto à curva inicial  $c_0$ .

Todos os pontos no interior possuem um valor positivo e no exterior um valor negativo, pelo que pode ser visto como:

$$\begin{cases} \frac{\partial \phi}{\partial t}(t, x, y) = V|\nabla \phi(t, x, y)|, t \in ]0, +\infty], (x, y) \in \Omega \\ \phi(0, x, y) = d((x, y), c_0) \\ \frac{\partial \phi}{\partial N} = 0, t \in ]0, +\infty], (x, y) \in \partial \Omega \end{cases} \quad (4.9)$$

O modelo estabelecido pela Equação (4.9) apresenta uma série de vantagens. Desde logo, permite alterações de topologia como a junção ou separação da interface. Por outro lado, as aproximações numéricas são simplificadas em virtude de o LS estar definido no domínio espacial da própria imagem. O cálculo das derivadas pode ser realizado por diferenças finitas e deixa de ser necessário o cálculo das derivadas da curva, o que nem sempre é simples de realizar. A *framework* permite definir os elementos geométricos intrínsecos à custa de  $\phi$ , designadamente a normal e a curvatura (condições necessárias para que qualquer representação possa ser útil). De facto é facilmente demonstrável que podem ser definidas como:

$$\vec{N} = -\frac{\nabla \phi}{|\nabla \phi|} \quad (4.10)$$

$$\kappa = \operatorname{div} \left( \frac{\nabla \phi}{|\nabla \phi|} \right) \quad (4.11)$$

em que  $\operatorname{div}(\bullet)$  representa o divergente. Por último, a metodologia pode ser expandida a problemas de dimensão superior (Aubert & Kornprobst, 2008; Sethian, 1999).

O problema da segmentação de imagens passa por encontrar a função  $V$  do modelo (4.9) que permita evoluir o LS para as regiões de interesse, no caso as regiões fronteira dos objetos. Na implementação paramétrica a evolução da curva, com a velocidade definida, é geralmente dada por:

$$\frac{\partial C}{\partial t} = (\kappa g - \langle \nabla g, N \rangle) N \quad (4.12)$$

onde  $\kappa$  representa a curvatura (vista em termos paramétricos),  $\langle \cdot \rangle$  o produto interno,  $N$  a normal e  $g$  uma função detetor de gradiente, função da imagem original filtrada e que pode tomar a forma de:

$$g(x,y) = \frac{1}{1 + \|\nabla(G_\sigma * I)\|^2} \quad (4.13)$$

onde  $G_\sigma$  é uma função gaussiana usada para filtrar a imagem original  $I$  e evitar os efeitos do ruído no gradiente. Desta forma nas regiões de elevado gradiente (regiões delimitadoras dos objetos)  $g(x,y)$  toma um valor baixo, enquanto que nas regiões de baixo gradiente tomará um valor elevado. A adição da unidade no denominador da função existe apenas para evitar a divisão por zero.

A Equação (4.12) permite encontrar uma curva que se dirija para as regiões de maior gradiente, ou dito por outras palavras, para a curva que minimiza  $\int g(x,y)$ , guiada e suavizada pela curvatura  $\kappa$ . O segundo termo, tem como função evitar a fuga da curva nos casos em que o gradiente não seja nulo contribuindo para que a evolução se realize no sentido do gradiente descendente.

Realizando a transposição para a *framework* LS o problema da segmentação pode ser definido como:

$$\frac{\partial \phi}{\partial t} = \left( \kappa g - \left\langle \nabla g, \frac{\nabla \phi}{\|\nabla \phi\|} \right\rangle \right) \|\nabla \phi\| \quad (4.14)$$

onde  $\kappa$  é definida pela Equação (4.11) e  $g$  uma função dependente da imagem que pode tomar a forma da Equação (4.13). A Equação (4.14) mostra que a evolução da curva pode ser vista como a evolução do LS, sendo que as operações numéricas são relativamente simples de realizar pois o LS reside na grelha da imagem. Como tal, operações como derivadas podem ser realizadas com diferenças finitas sobre a grelha.

A partir do momento em que  $\phi$  e  $V$  sejam conhecidas para cada ponto da grelha Cartesiana (ou numa região suficientemente próxima da interface),  $\phi$  pode ser evoluído ao longo do tempo e, por consequência, a interface (Osher & Fedkiw, 2003). A discretização do problema representado pela Equação (4.14) é realizado através de um esquema *upwind* de primeira ordem (outras formas podem ser usadas, dependendo da precisão requerida para o problema) (Aubert & Kornprobst, 2008; Osher & Fedkiw, 2003; Sethian, 1999).

Um dos problemas que o método apresenta relaciona-se com a evolução de  $\phi$  por ação de  $V$ . Após algum tempo de evolução  $\phi$  deixa de ser uma função distância com sinal, pelo que algumas das simplificações numéricas deixam de poder ser aplicadas (Osher & Fedkiw, 2003). Nestes casos é

sugerida a reinicialização periódica da FLS, de acordo com a Equação (4.15) (outras formas podem ser usadas), por forma a mantê-la como uma função distância com sinal. Isto permite manter  $\phi$  suavizada para se poder aproximar as suas derivadas com um determinado nível de precisão (Osher & Fedkiw, 2003).

$$\frac{\partial \phi}{\partial t} = \text{sign}(\phi_0)(1 - \nabla \phi) \quad (4.15)$$

Na equação anterior  $\phi_0$  representa a função a inicializar e  $\text{sign}(\bullet)$  a função sinal.

Concluindo, a *framework* LS permite analisar o problema da evolução da curva numa perspetiva simplificada. A definição implícita da curva permite reduzir o processo de cálculo numérico assim como tornar o processo independente de variações topológicas.

Naturalmente, como todos os métodos, possui algumas desvantagens e que já foram enunciadas nesta secção. Apesar disso, as vantagens da sua utilização são significativas, pelo que são inúmeros os trabalhos relacionados com modelos deformáveis ou contornos ativos que fazem uso da *framework* para realizarem a implementação da evolução da curva com resultados muito satisfatórios que justificam a sua aplicação ao problema da segmentação de imagens fetais (Balla-Arabé, Gao, & Bin Wang, 2013; Fox, 2010; Malladi & Sethian, 1996; A. Singh, Goldgof, & Terzopoulos, 1998).

#### 4.4 Contornos Ativos sem Gradiente – Chan - Vese

De uma forma geral os métodos clássicos de contornos ativos usam uma função dependente do gradiente como critério de paragem (Chan & Vese, 2001). Isto mesmo está expresso nas secções anteriores onde foi analisado a utilização de detetores de contornos baseados no gradiente para realizar a paragem da evolução da curva.

Um dos problemas relacionados com a utilização do gradiente, especialmente em casos de imagens com ruído intenso, é que o gradiente é limitado pelo que o detetor (do tipo da Equação (4.13)) nunca é zero e a curva pode evoluir para além do contorno (Chan & Vese, 2001).

Chan e Vese (Chan & Vese, 2001) introduziram um modelo de contornos ativos cuja condição de paragem não depende do gradiente da imagem. O algoritmo usa métodos de cálculo de variações para fazer evoluir uma FLS. O objetivo é encontrar a FLS que minimiza uma função de custo, definida pelos autores com base no modelo de segmentação Mumford–Shah (Mumford & Shah, 1989). O modelo assume que uma imagem é aproximada por duas regiões de intensidades constantes e distintas cuja

linha de separação é definida pelo contorno (a curva de separação) e que pode ser visto na Equação (4.16).

$$F(c_1, c_2, C) = \mu \text{Length}(C) + \nu \text{Area}_{in}(C) + \lambda_1 \int_{in} |I(x, y) - c_1|^2 dx dy + \lambda_2 \int_{out} |I(x, y) - c_2|^2 dx dy \quad (4.16)$$

Na equação anterior  $I$  representa a imagem,  $c_1$  a média de  $I$  no interior da curva  $C$ ,  $c_2$  a média de  $I$  no exterior de  $C$ ,  $\text{Length}(\bullet)$  o comprimento de  $C$  e  $\text{Area}_{in}(\bullet)$  a área no interior de  $C$ .  $\mu$ ,  $\nu$ ,  $\lambda_1$  e  $\lambda_2$  são parâmetros fixos com  $\mu \geq 0$ ,  $\nu \geq 0$ ,  $\lambda_1 > 0$  e  $\lambda_2 > 0$  (Chan & Vese, 2001). Os termos dependentes de  $\text{Length}(\bullet)$  e de  $\text{Area}_{in}(\bullet)$  funcionam como termos regularizadores. O minimizante corresponderá à curva  $C$  que coincida com o contorno dos objetos.

Na secção anterior foi visto que a curva  $C$  pode ser representada pelo LS zero de uma superfície (FLS). Isto significa que o problema pode ser transposto para a *framework* LS. Após a transformação o novo funcional (regularizado) pode ser expresso por:

$$F_\epsilon(c_1, c_2, \phi) = \mu \int_{\Omega} \delta_\epsilon(\phi(x, y)) |\nabla \phi(x, y)| dx dy + \nu \int_{\Omega} H_\epsilon(\phi(x, y)) + \lambda_1 \int_{\Omega} |I(x, y) - c_1|^2 H_\epsilon(\phi(x, y)) dx dy + \lambda_2 \int_{\Omega} |I(x, y) - c_2|^2 (1 - H_\epsilon(\phi(x, y))) dx dy \quad (4.17)$$

Na Equação (4.17)  $\phi$  representa a FLS,  $H_\epsilon$  e  $\delta_\epsilon$  versões regularizadas (suavizadas) da função Heaviside e Dirac, respetivamente, definidas em (Chan & Vese, 2001) e  $c_1$  e  $c_2$  as constantes expressas em função de  $\phi$  que podem ser vistas como:

$$\begin{cases} c_1(\phi) = \text{média}(I) \text{ em } \phi \geq 0 \\ c_2(\phi) = \text{média}(I) \text{ em } \phi < 0 \end{cases} \quad (4.18)$$

onde  $\phi \geq 0$  representa a região interior ao LS zero e  $\phi < 0$  a região exterior.

A minimização de  $F_\epsilon$  conduz ao modelo:

$$\begin{aligned} \frac{\partial \phi}{\partial t} &= \delta_\epsilon(\phi) \left[ \mu \text{div} \left( \frac{\nabla \phi}{|\nabla \phi|} \right) - \nu - \lambda_1 (I - c_1)^2 + \lambda_2 (I - c_2)^2 \right] = 0 \text{ em } (0, \infty) \times \Omega \\ \phi(0, x, y) &= \phi_0(x, y) \text{ em } \Omega \\ \frac{\delta_\epsilon(\phi)}{|\nabla \phi|} \frac{\partial \phi}{\partial \vec{n}} &= 0 \text{ em } \partial \Omega \end{aligned} \quad (4.19)$$

A Equação (4.19) traduz a evolução do LS sujeito às restrições indicadas, com  $\vec{n}$  a representar a normal exterior ao contorno  $\partial\Omega$  (com  $\Omega$  a representar o domínio da imagem).

Note-se que, contrariamente à definição exposta na secção anterior, a propagação da curva não depende do gradiente da imagem o que representa uma vantagem em condições adversas como a presença de ruído.

A implementação numérica obedece aos pressupostos indicados na secção anterior, sendo que a discretização se encontra bem definida na literatura (Chan & Vese, 2001) (Anexo B).

Um dos inconvenientes da utilização deste tipo de metodologias tem a ver com a aproximação inicial (contorno inicial). Os modelos deformáveis necessitam partir de uma curva inicial para se deslocarem em direção ao contorno. Esta aproximação é, geralmente, feita manualmente o que constitui um inconveniente na sua utilização em processos automáticos de deteção de contornos. Para contornar este problema foram usadas neste trabalho duas abordagens distintas. A primeira consistiu em partir de uma FLS pré-definida. A segunda consistiu em usar como contorno inicial o resultado da aplicação dos métodos FCM, concretamente o GKFCM. Desta forma, pretende-se que o contorno inicial esteja próximo do contorno real, pelo que a convergência será mais rápida. Estas estratégias foram aplicadas às imagens fetais.

Outro problema relevante é que o desempenho do método está dependente da parametrização usada, nomeadamente, dos pesos atribuídos à componente interna ao contorno, à componente externa e ao comprimento da curva, bem identificados na função de custo da Equação (4.17). Este aspeto é relevante quando se pretende um algoritmo generalista, invariante ao tipo de imagem e que não necessite uma reparametrização individual para cada tipo de imagem estudada. Esta questão será abordada mais em pormenor no capítulo 6, onde são apresentados os resultados obtidos da aplicação do método às imagens fetais.

## **4.5 Conclusão**

Neste capítulo foi introduzido o conceito de contornos ativos e apresentada uma ferramenta para a representação implícita da curva com vista à simplificação do cálculo da evolução da curva. Foi também apresentado o método Chan-Vese usado na segmentação de imagens, nomeadamente médicas, e que permite realizar a evolução da curva sem utilizar o gradiente da imagem, melhorando o desempenho na presença de ruído.

Um dos problemas com que temos que lidar neste tipo de algoritmos está relacionado com a aproximação inicial do contorno, geralmente, fornecido de forma manual o que limita a sua utilização quando se tratam de métodos automáticos. Neste contexto realizaram-se, neste trabalho, várias experiências para avaliar o comportamento deste tipo de metodologias com diversas aproximações iniciais da curva, designadamente, quando esta é fornecida pela segmentação difusa usada no capítulo anterior. Foi também avaliado o comportamento do desempenho do algoritmo perante diversas parametrizações e a sua capacidade de generalização sem necessidade de reparametrização. Os resultados são apresentados e discutidos no capítulo 6.



## 5. SEGMENTAÇÃO POR APRENDIZAGEM

### 5.1 Introdução

A partir das observações realizadas é possível criar modelos que permitam inferir respostas para situações ainda não observadas – modelos de previsão. Este tipo de modelação é designado por modelação empírica (Gunn, 1998). Os últimos tempos têm sido férteis no desenvolvimento de métodos e aplicações deste tipo, nos mais variados domínios, designadamente no reconhecimento de carateres (Cortes & Vapnik, 1995), reconhecimento de objetos (Blanz *et al.*, 1996), reconhecimento de voz (Schmidt, 1996), reconhecimento facial (Osuna, Freund, & Girosi, 1997), sistemas de identificação biométricos (Ma & Guo, 2014) e na classificação de imagens (Rodrigues, 2008), entre outras.

Neste tipo de modelação, a quantidade e qualidade dos dados determinam o desempenho e qualidade do modelo, pelo que este sofrerá sempre do facto de os dados obtidos apenas representarem uma parte das possibilidades para o espaço de entrada (Gunn, 1998), resultando em problemas, quase sempre do tipo *ill posed*. Por este motivo, as abordagens típicas como as redes neuronais, podem ter dificuldades de generalização, produzindo modelos que podem incorrer no chamado *overfitting*, consequência dos algoritmos de otimização, da estrutura não adequada (capacidade) e das medidas estatísticas usados na obtenção do melhor modelo (Gunn, 1998). Estes aspetos estiveram na base do desenvolvimento das *Support Vector Machines* (SVMs) (Vapnik, 1995; 1998). De forma muito simples, um mecanismo de aprendizagem, para um determinado conjunto finito de treino, alcança a generalização, potencialmente ótima, se equilibrar de forma adequada a precisão atingida nesse conjunto e a sua capacidade ou habilidade de reconhecer um outro conjunto sem erro. Uma máquina muito adaptada pode ser levada a uma má classificação quando confrontada com dados de entrada ligeiramente distintos dos do treino ou, em oposição, uma máquina pouco adaptada pode incorrer em classificar positivamente objetos distintos apenas porque uma das características se verifica (Burges, 1998). Um exemplo frequentemente usado para ilustrar este aspeto é o do botânico. Um botânico com uma memória fotográfica quando confrontado com uma nova árvore conclui que não é uma árvore apenas pelo facto de esta não apresentar o mesmo número de ramos ou de folhas que as árvores com que foi treinado. Um botânico mais relaxado ou preguiçoso, identifica tudo como sendo árvore apenas porque é verde (Burges, 1998). Nenhum destes casos é adequado e as SVMs tentam resolver estes aspetos, conhecidos como capacidade de generalização.

As SVMs constituem um tipo de modelo que inclui na sua formulação a Minimização do Risco Estrutural (SRM – *Structural Risk Minimisation*) em detrimento da Minimização do Risco Empírico (ERM – *Empirical Risk Minimisation*). Ao contrário do ERM, que minimiza apenas o erro sobre os dados de treino o SRM minimiza o limite superior do risco esperado, que integra a capacidade da máquina, o que dá à SVM uma maior capacidade de generalização (Gunn, 1998).

Face ao exposto, é expectável que, num contexto de *Machine Learning* (ML), a utilização das SVMs na segmentação das imagens fetais possa resolver o problema da generalização inerente aos métodos já apresentados e usados. A possibilidade de incluir no mecanismo de aprendizagem informação da morfologia pode contribuir para uma melhoria do segmentador, nomeadamente nos casos em que os algoritmos descritos nas secções anteriores e discutidos no capítulo 6 falham.

Este capítulo pretende introduzir os conceitos associados às SVMs e descrever os mecanismos usados no processo de treino, designadamente no que à escolha do espaço de características usado no treino da SVM diz respeito.

## 5.2 Aprendizagem Estatística

Alguns dos aspetos que estão na base da formulação das SVMs tiveram início em 1979 com Vapnik (Vapnik, 1982), considerado um dos trabalhos mais importantes na área da aprendizagem estatística.

Na Teoria da Aprendizagem Estatística considera-se o espaço de soluções, designado por Espaço Alvo e aqui representado por  $T$ , no qual se pressupõe a existência de uma função  $f_0(x)$  que modela o problema da aprendizagem para os padrões  $x$  de forma ótima. Este espaço não é possível de ser caracterizado na sua totalidade pois o número de padrões disponíveis para o fazer é limitado. O processo de modelação recorre a um espaço de menor complexidade, designado por Espaço de Hipóteses,  $H_n$  (em que  $n$  representa a complexidade), no qual é possível seleccionar um modelo  $f_n(x)$  que mais se aproxima (de acordo com a medida usada) da função ótima  $f_0(x)$  (Gunn, 1998; Rodrigues, 2008). Deste mecanismo resultam o Erro de Aproximação e o Erro de Estimativa. O primeiro resulta do facto de  $H_n$  ser inferior a  $T$ , pelo que o modelo ótimo pode residir fora do espaço de hipóteses e, como tal, o modelo utilizado conduzir a erros de aproximação elevados. O erro de estimativa resulta do processo de aprendizagem e é consequência da escolha de um modelo não ótimo dentro do espaço de hipóteses. O objetivo é encontrar, dentro das possibilidades do espaço de hipóteses, uma função  $\hat{f}_{n,l}(x)$  que aproxime o melhor possível  $f_n(x)$ . A Figura 5.1 ilustra de forma mais perceptível estes dois aspetos.




Figura 5.1 – Erros de modelação vistos nos espaços de soluções (Adaptado de (Gunn, 1998)).

Da soma do Erro de Aproximação com o Erro de Estimativa resulta o Erro de Generalização e que, na prática, interessa minimizar pois é indicador do comportamento do modelo perante padrões distintos dos usados na fase de treino. Neste contexto o objetivo de um qualquer mecanismo de aprendizagem é encontrar o melhor modelo do espaço de hipóteses que, de acordo com os padrões de treino existentes, reduza o Erro de Generalização a um mínimo possível. Para que este erro seja mínimo não basta que o classificador realize a separação das classes para os elementos de treino. É necessário que o faça também para os possíveis elementos pós-treino e que, como já foi referido, poderão ser distintos. Para que isto seja possível o elemento separador, no espaço de classificação, deve garantir a maximização da distância aos elementos de treino de cada classe mais próximos. Desta forma é possível reduzir o risco de padrões ultrapassarem o hiperplano separador na fase pós-treino e, consequentemente, sejam mal classificados.

Pretende-se, pois, encontrar uma função  $f$  que minimize esse risco:

$$R[f] = \int_{\mathbf{x} \times \mathbf{y}} L(y, f(\mathbf{x})) P(\mathbf{x}, y) d\mathbf{x} dy \quad (5.1)$$

Em que  $L$  representa uma função indicadora ou avaliadora da diferença entre o valor desejado e o valor obtido para o padrão de treino  $(\mathbf{x}, y)$  pela função  $f$  para a entrada  $\mathbf{x}$ .  $P(\mathbf{x}, y)$  corresponde à distribuição probabilística do par  $(\mathbf{x}, y)$ . Contudo, a distribuição  $P(\mathbf{x}, y)$  não é conhecida. Apesar

disso, é possível encontrar uma aproximação,  $\hat{f}_{n,l}(\mathbf{x})$ , que minimize o Risco Empírico,  $R_{emp}$ , dado por:

$$R_{emp}[f] = \frac{1}{l} \sum_{i=1}^l (y_i - f(\mathbf{x}_i))^2 \quad (5.2)$$

Na Equação (5.2),  $(y_i - f(\mathbf{x}_i))^2$  representa uma possível função  $L$  e  $l$  o número de padrões.

Desta forma a aproximação será dada pelo modelo, dentro do espaço de hipóteses, que minimiza  $R_{emp}$ , tal como apresentado na Equação (5.3).

$$\hat{f}_{n,l}(\mathbf{x}) = \arg \min_{f \in H_n} R_{emp}[f] \quad (5.3)$$

A minimização do Risco Empírico só faz sentido se:

$$\lim_{l \rightarrow \infty} R_{emp}[f] = R[f] \quad (5.4)$$

A Equação (5.4) é válida para valores de  $l$  elevados mas obriga a que a Equação (5.5) seja verificada.

$$\lim_{l \rightarrow \infty} \min_{f \in H_n} R_{emp}[f] = \min_{f \in H_n} R[f] \quad (5.5)$$

E que é válida para um espaço de hipóteses,  $H_n$ , reduzido.

Assim, a inequação seguinte (Equação (5.6)), é necessária para estabelecer o limite superior para o risco, com uma probabilidade  $1 - \delta$  e na qual  $h$  representa a dimensão Vapnik-Chervonenkis do espaço de hipóteses e que é independente da distribuição probabilística  $P(\mathbf{x}, y)$ .

$$R[f] \leq R_{emp}[f] + \sqrt{\frac{h \left( \ln \frac{2l}{h} + 1 \right) - \ln \left( \frac{\delta}{4} \right)}{l}} \quad (5.6)$$

### 5.3 Dimensão Vapnik-Chervonenkis (VC)

Considere-se o caso das funções de classificação para duas classes de tal forma que  $f(\mathbf{x}, \alpha) \in \{-1, 1\}$ , qualquer que seja  $\mathbf{x}$  e com  $\alpha$  a representar um conjunto específico de parâmetros. Se um determinado conjunto de pontos,  $l$ , pode ser classificado de todas as formas possíveis,  $2^l$ , e se para cada classificação é possível encontrar uma função  $f$  de entre o conjunto de possíveis funções que realiza essa mesma atribuição então diz-se que esse conjunto de pontos é

separado por esse conjunto de funções (Burges, 1998). A dimensão VC para o conjunto de funções  $\{f(\alpha)\}$  é definida como o número máximo de pontos de treino separáveis por  $\{f(\alpha)\}$ . Se a dimensão VC é  $h$  então existe pelo menos um conjunto de pontos com cardinalidade  $h$  que podem ser separados. Não significa, no entanto, que todos os subconjuntos de pontos possam ser separados (Burges, 1998).

Considere-se o caso de  $l = 3$ , com cada ponto definido em  $\mathbb{R}^2$  e com  $\{f(\alpha)\}$  a representar o conjunto de retas orientadas que realizam a classificação de cada ponto ao conjunto  $\{-1, 1\}$ . Nestas condições é possível encontrar uma separação, de entre o conjunto possível  $\{f(\alpha)\}$ , que classifica corretamente 3 pontos. Diz-se que a dimensão VC é 3. A Figura 5.2 ilustra de forma mais clara este aspeto.




Figura 5.2 – Separação, por retas orientadas, de 3 pontos em  $\mathbb{R}^2$ . Os pontos a cheio representam uma classe e a vazia a outra (adaptada de (Burges, 1998)).

Note-se, que para o caso de 4 pontos em  $\mathbb{R}^2$ , não seria possível realizar sempre a separação dos 4 pontos através da escolha adequada de uma reta orientada (Figura 5.3). Nesta situação existem várias combinações possíveis da distribuição dos pontos pelas duas classes em que não é possível realizar a separação completa de todos os pontos para a respetiva classe. A Figura 5.3 apresenta duas dessas possibilidades. Neste caso, as duas funções separadoras representadas apenas realizam a separação de 3 pontos de forma correta. Estes classificadores continuariam a ter uma dimensão VC 3.

A expansão do conceito de dimensão VC para  $\mathbb{R}^n$  estabelece que a dimensão VC do conjunto de hiperplanos orientados é  $n + 1$ .




Figura 5.3 – Exemplo da dimensão VC para 4 pontos em  $\mathbb{R}^2$ . Nem todos os classificadores usados realizam a separação de todos os pontos, independentemente da distribuição dos mesmos pelas duas classes. Para a distribuição das classes definida e para as duas funções separadoras selecionadas apenas é possível separar corretamente 3 dos 4 pontos.

Face ao exposto é “*imperativo restringir o conjunto de funções, das quais  $f$  é escolhido, a um conjunto adequado à dimensão do conjunto de padrões de treino. A redução desse conjunto está dependente do risco empírico e da capacidade da função de classificação  $f$* ” (Rodrigues, 2008). Pode-se então afirmar que o coeficiente VC quantifica a capacidade da máquina de aprendizagem.

## 5.4 Minimização do Risco Estrutural

Tal como referido na introdução deste capítulo uma das vantagens das SVMs relativamente às redes neurais é a sua capacidade de generalização. Esta, resulta do facto de as SVMs recorrerem à minimização do Erro Estrutural em detrimento da minimização do Erro Empírico.

A avaliação da Equação (5.6) mostra que o termo dependente da confiança VC depende da classe de funções usadas, enquanto que o risco empírico e o risco efetivo dependem da função particular selecionada pelo processo de treino (Burges, 1998). O objetivo é, por isso, encontrar um subconjunto de funções, dentro do conjunto de funções, para o qual o risco é minimizado. A minimização do risco estrutural consiste em encontrar esse subconjunto de funções que minimiza o risco efetivo, o que pode ser atingido pelo treino de várias máquinas de aprendizagem (um para cada subconjunto definido) com o objetivo de minimizar o risco empírico (Figura 5.4). Após esse treino é selecionado o modelo cuja soma do risco empírico com a confiança VC é mínima.




Figura 5.4 – Subespaços de hipóteses ordenados pela dimensão VC.

Desta forma, a minimização do erro estrutural, consiste em encontrar um espaço de hipóteses que minimize a combinação do risco empírico com a dimensão VC para o conjunto de dados de treino e para um determinado valor probabilístico  $1 - \delta$  (Equação (5.7)).

$$\min_{H_h} R_{emp}[f] + \sqrt{\frac{h \left( \ln \frac{2l}{h} + 1 \right) - \ln \left( \frac{\delta}{4} \right)}{l}} \quad (5.7)$$

## 5.5 Classificação com Vetores de Suporte

Apesar de o caso de classificação para múltiplas classes por aplicação das SVMs estar bem estabelecido e formulado na diversa literatura sobre o assunto as secções seguintes referem-se apenas ao caso simplificado para duas classes. Isto não implica perda de generalização e está perfeitamente adaptado ao contexto deste trabalho.

Um classificador tem por objetivo separar um conjunto de padrões pelas respetivas classes a que pertencem e deve produzir bons resultados mesmo para padrões não observados na fase de treino.

Dito de outra forma, o modelo encontrado deve possuir capacidade de generalização. No caso das SVMs, isto é alcançado pela minimização do Erro Estrutural, tal como referido na secção anterior deste capítulo.

Quando lidamos com este tipo de problemas podem ocorrer diversas situações que obrigam a alterar a estratégia para encontrar o melhor classificador possível. As secções seguintes apresentam alguns desses casos.

### 5.5.1 Separação Linear

A separação linear refere-se ao tipo de problemas em que a distribuição dos padrões pelas respetivas classes permite encontrar um modelo de classificação linear. Neste caso, a solução é um elemento separador que permite realizar essa tarefa com o mínimo erro possível. Quando em  $\mathbb{R}^2$  o hiperplano corresponde a uma reta, em  $\mathbb{R}^3$  a um plano e assim sucessivamente. Note-se que a dimensão do hiperplano para dados em  $\mathbb{R}^n$  é  $n - 1$ .

Por facilidade de abstração considere-se o espaço  $\mathbb{R}^2$ . Considere-se também que são permitidas duas classes distintas para os padrões definidos. Os padrões serão então definidos pelos pares  $(\mathbf{x}_i, y_i)$ , com  $i = 1, 2, \dots, l$ ,  $\mathbf{x}_i = (x_{1i}, x_{2i})$  representa as características usadas na classificação de cada padrão

e  $y_i \in \{-1, 1\}$  a classe observada para cada padrão de entrada. Se os dados são separáveis linearmente, então existe uma infinidade de hiperplanos que permitem realizar a classificação (Figura 5.5).




Figura 5.5 – Hiperplanos de separação possíveis para padrões linearmente separáveis em  $\mathbb{R}^2$ .

No caso das SVMs é encontrado o hiperplano que maximiza a distância aos pontos mais próximos e que são designados por vetores de suporte (Figura 5.6). Este é o hiperplano ótimo e corresponde à solução que possui melhor capacidade de generalização.




Figura 5.6 – Hiperplano ótimo que maximiza a distância entre as classes. Os pontos mais próximos do hiperplano são designados por vetores de suporte (representados a cheio).



A questão que se coloca é como poderá ser encontrado o hiperplano ótimo?

Considerando o hiperplano que realiza a separação dos casos positivos dos negativos (supondo  $y_i \in \{-1, 1\}$ ) a equação dos pontos  $\mathbf{x}$  que se encontram sobre o hiperplano são soluções da equação:

$$\langle \boldsymbol{\omega}, \mathbf{x} \rangle + b = 0 \quad (5.8)$$

Em que  $\boldsymbol{\omega}$  é normal ao hiperplano e  $\langle \cdot \rangle$  representa o produto vetorial. A distância da origem ao hiperplano, na direção perpendicular, será dada por  $|b|/\|\boldsymbol{\omega}\|$ . Considere-se também que a distância do hiperplano ótimo ao exemplo positivo e ao exemplo negativo mais próximo é dada, respetivamente, por  $d^+$  e  $d^-$ . A margem de separação do hiperplano ótimo será  $d^+ + d^-$ . O hiperplano ótimo é aquele que maximiza esta margem (Figura 5.7).




Figura 5.7 – Hiperplano de separação linear ótimo. Os padrões vetores de suporte estão assinalados com um círculo envolvente.

Considere-se que todos os pontos de treino obedecem às seguintes restrições:

$$\langle \mathbf{x}_i, \boldsymbol{\omega} \rangle + b \geq +1 \quad \text{para } y_i = +1 \quad (5.9)$$

$$\langle \mathbf{x}_i, \boldsymbol{\omega} \rangle + b \leq -1 \quad \text{para } y_i = -1 \quad (5.10)$$

As restrições dadas pelas equações (5.9) e (5.10) podem ser substituídas por:

$$y_i (\langle \mathbf{x}_i, \boldsymbol{\omega} \rangle + b) - 1 \geq 0 \quad \forall i \quad (5.11)$$

Todos os pontos que verificam a Equação (5.9) encontram-se sobre o hiperplano  $H_1$  pelo que  $\langle \mathbf{x}_i, \boldsymbol{\omega} \rangle + b = 1$ . Isto significa que a distância à origem, na perpendicular, será dada por  $|1 - b| / \|\boldsymbol{\omega}\|$ . No mesmo sentido um qualquer ponto do hiperplano  $H_2$  obedecerá à igualdade  $\langle \mathbf{x}_i, \boldsymbol{\omega} \rangle + b = -1$  e a distância do hiperplano à origem será  $|-1 - b| / \|\boldsymbol{\omega}\|$ . Dado que  $d^+ = d^- = 1 / \|\boldsymbol{\omega}\|$  a margem será  $2 / \|\boldsymbol{\omega}\|$ . Desta forma o par de hiperplanos que maximiza a margem pode ser obtido pela minimização de  $\|\boldsymbol{\omega}\|^2$  sujeita às restrições impostas pela Equação (5.11).

Por conveniência matemática a minimização de  $\|\boldsymbol{\omega}\|^2$  pode ser vista como a minimização de  $\frac{1}{2} \|\boldsymbol{\omega}\|^2$ , pelo que o problema a resolver é a minimização da função de custo da Equação (5.12) sujeita às restrições indicadas pela Equação (5.13) e com  $N$  a indicar o número de características dos dados de entrada. Este é um problema de programação quadrática convexa e é designada como a formulação primal das SVMs lineares.

$$J = \frac{1}{2} \sum_{k=1}^N \omega_k^2 \quad (5.12)$$

$$y_i (\langle \mathbf{x}_i, \boldsymbol{\omega} \rangle + b) - 1 \geq 0 \quad (5.13)$$

Steve Gunn, (Gunn, 1998), demonstra que a minimização da Equação (5.12) é equivalente a minimizar o Erro Estrutural que, como já referido, constitui uma melhoria da capacidade de generalização da máquina de aprendizagem.

Por conveniência de resolução do problema esta formulação é transformada numa formulação Lagrangiana (Burgess, 1998). Esta transformação permite que as restrições impostas sejam substituídas por restrições nos multiplicadores de Lagrange e que são mais simples de tratar. Por outro lado, os dados de treino só aparecerão, no treino e nos testes, na forma de produto vetoriais. Esta propriedade é crucial pois permite a generalização para o caso da separação não-linear (Burgess, 1998).

A formulação Lagrangiana do problema passa a:

$$\Lambda_p(\boldsymbol{\omega}, b, \boldsymbol{\alpha}) = \frac{1}{2} \|\boldsymbol{\omega}\|^2 - \sum_{i=1}^l \alpha_i y_i (\langle \boldsymbol{\omega}, \mathbf{x}_i \rangle + b) + \sum_{i=1}^l \alpha_i \quad (5.14)$$

em que  $\alpha$  representa os multiplicadores de Lagrange e  $l$  o número total de padrões. A solução passa pela minimização do Lagrangiano com respeito a  $\boldsymbol{\omega}$  e  $b$  e requer, simultaneamente, que a derivada em relação a  $\alpha$  desapareça, sujeito às restrições que  $\alpha_i \geq 0$ . A solução será dada por:

$$\frac{\partial \Lambda_P}{\partial b} = 0 \Rightarrow \sum_i \alpha_i y_i = 0 \quad (5.15)$$

$$\frac{\partial \Lambda_P}{\partial \mathbf{w}} = 0 \Rightarrow \mathbf{w} = \sum_i \alpha_i y_i \mathbf{x}_i \quad (5.16)$$

Substituindo o resultado das equações (5.15) e (5.16) na formulação primal, Equação (5.14), obtém-se a formulação dual do problema:

$$\Lambda_D = \sum_{i=1} \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j \langle \mathbf{x}_i, \mathbf{x}_j \rangle \quad (5.17)$$

O objetivo agora é maximizar o Lagrangiano,  $\Lambda_D$ , com respeito a  $\alpha$  sujeito às restrições  $\alpha_i \geq 0$  e  $\sum_i \alpha_i y_i = 0$ .

A solução do problema passa então pela minimização de  $\Lambda_P$  ou pela maximização de  $\Lambda_D$ , dependendo se optamos pela formulação primal ou dual, respetivamente.

Como nota final é importante referir que o problema de separação linear se pode resumir à maximização de  $\Lambda_D$  sujeita às restrições de positividade de  $\alpha_i$  e a  $\sum_i \alpha_i y_i = 0$ . Para cada ponto de treino existirá um multiplicador de Lagrange,  $\alpha_i$ . Todos os pontos para os quais  $\alpha_i > 0$  são designados por vetores de suporte. Estes pontos pertencem a um dos hiperplanos  $H_1$  ou  $H_2$  (Figura 5.7). Os restantes pontos de treino  $\alpha_i = 0$  e tanto podem estar num dos lados de  $H_1$  ou  $H_2$ .

Os vetores de suporte são, por isso, os pontos críticos para uma máquina de aprendizagem deste tipo: SVM. Eles são os pontos mais próximos do limite de decisão. Se todos os restantes pontos fossem removidos ou alterados dentro de cada hiperplano separador a solução encontrada seria exatamente a mesma (Burgess, 1998).

### 5.5.2 Separação Linear em Dados Não Separáveis Linearmente

Um dos problemas do algoritmo descrito na secção anterior é que não funciona quando não existe separabilidade linear dos dados. Pode acontecer que dados de uma classe surjam no espaço da outra. Nestes casos é impossível encontrar uma função linear que resolva o problema. Diz-se, nestas situações, que os dados não separáveis linearmente (Figura 5.8). Então o que fazer nestes casos? Cortes e Vapnik, (Cortes & Vapnik, 1995), introduziram na função de custo formulada para o problema de separação linear e descrita na Equação (5.12) um termo adicional com um conjunto de variáveis,

$\xi_i$ , que descrevem o erro de classificação dos pontos de treino. A nova função de custo passa a ser representada por:

$$J = \frac{1}{2} \|\omega\|^2 + C \sum_i \xi_i \quad (5.18)$$




Figura 5.8 – Exemplo de uma distribuição dos padrões de treino em que não é possível realizar a separação linear das classes.

Cada coeficiente  $\xi_i$  é zero nos casos em que não existe erro de classificação e toma um valor positivo nos restantes casos. O valor assumido é dado pela distância do hiperplano separador ao ponto mal classificado.  $C$  é definido pelo utilizador e é usado para penalizar os erros.

A minimização de (5.18) obedece às restrições:

$$y_i (\langle \omega, \mathbf{x}_i \rangle + b) \geq 1 - \xi_i \quad (5.19)$$

Novamente, recorrendo à representação Lagrangiana do problema e à formulação dual, a solução pode ser encontrada pela maximização de:

$$\Lambda_D = \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j \langle \mathbf{x}_i, \mathbf{x}_j \rangle \quad (5.20)$$

sujeita às restrições:

$$0 \leq \alpha_i \leq C \quad (5.21)$$

$$\sum_i \alpha_i y_i = 0 \quad (5.22)$$

E a solução dada por:

$$\mathbf{w} = \sum_{i=1}^{N_s} \alpha_i y_i \mathbf{x}_i \quad (5.23)$$

sendo  $N_s$  o número de vetores de suporte.

No caso da formulação primal do problema de otimização, o respetivo Lagrangiano é dado por:

$$\Lambda_P = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_i \xi_i - \sum_i \alpha_i \left[ y_i (\langle \mathbf{w}, \mathbf{x}_i \rangle + b) - 1 + \xi_i \right] - \sum_i \mu_i \xi_i \quad (5.24)$$

em que  $\mu_i$  são os coeficientes de Lagrange introduzidos para reforçar a positividade de  $\xi_i$ . As condições impostas serão:

$$\frac{\partial \Lambda_P}{\partial \mathbf{w}} = \mathbf{w} - \sum_i \alpha_i y_i \mathbf{x}_i = 0 \quad (5.25)$$

$$\frac{\partial \Lambda_P}{\partial b} = - \sum_i \alpha_i y_i = 0 \quad (5.26)$$

$$\frac{\partial \Lambda_P}{\partial \xi_i} = C - \alpha_i - \mu_i = 0 \quad (5.27)$$

$$y_i (\langle \mathbf{w}, \mathbf{x}_i \rangle + b) - 1 + \xi_i \geq 0 \quad (5.28)$$

$$\xi_i \geq 0 \quad (5.29)$$

$$\alpha_i \geq 0 \quad (5.30)$$

$$\mu_i \geq 0 \quad (5.31)$$

$$\alpha_i \left[ y_i (\langle \mathbf{w}, \mathbf{x}_i \rangle + b) - 1 + \xi_i \right] = 0 \quad (5.32)$$

$$\mu_i \xi_i = 0 \quad (5.33)$$

Estas condições, designadas por condições Karush-Kuhn-Tucker são importantes para a formulação e resolução do problema primal. As equações (5.32) e (5.33) permitem encontrar o *offset*  $b$ . Note-se que a combinação da Equação (5.27) com a Equação (5.33) estabelece que  $\xi_i = 0$  quando  $\alpha_i < C$ , pelo que podemos usar um qualquer ponto de treino para o qual  $0 < \alpha_i < C$  e, através da Equação (5.32), determinar  $b$  (com  $\xi_i = 0$ ) (Burges, 1998).

## 5.5.3 Separação Não-Linear

A secção anterior apresentou o caso de separação linear para dados não separáveis linearmente. Este tipo de metodologia é praticável em casos em que é aceitável uma margem mínima de erro de classificação. Estes dados são normalmente designados por *outliers* e podem ser o resultado da influência do ruído. Existem, no entanto, situações em que os dados não podem ser separados, com erro aceitável, por nenhum dos mecanismos abordados até ao momento. A Figura 5.9 é um possível exemplo.

A solução para este tipo de problemas passa por remapear os dados para um espaço de características de dimensão superior onde o problema possa ser resolvido linearmente pelo método já enunciado.




Figura 5.9 – Dados com características que não permitem uma separação linear.

Considere-se uma transformação,  $\Phi$ , que permite mapear os dados originais para um espaço de dimensão superior tal que:

$$\Phi: \mathbb{R}^d \mapsto H \quad (5.34)$$

Nas equações (5.20) - (5.22) os dados de treino surgem na forma de produtos vetoriais dos vetores de entrada  $\mathbf{x}_i, \mathbf{x}_j$ , pelo que o treino dependerá em  $H$  do produto vetorial de  $\langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle$ . Se existir uma função  $K(\mathbf{x}_i, \mathbf{x}_j) = \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle$ , designada por *kernel*, então o treino dependerá apenas de  $K$  e não será necessário conhecer  $\Phi$ . O problema a minimizar será do tipo:

$$\sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \quad (5.35)$$

sendo que as restrições se mantêm inalteradas e dadas por:

$$0 \leq \alpha_i \leq C \quad (5.36)$$

$$\sum_i \alpha_i y_i = 0 \quad (5.37)$$

O mesmo pode ser concluído para a fase de teste. Nesta fase são calculados os produtos vetoriais de cada ponto de teste com os pesos  $\omega$ . No caso da transformação, este produto pode ser substituído pelo produto vetorial da transformação de acordo com:

$$f(\mathbf{x}) = \sum_{i=1}^{N_s} \alpha_i y_i \langle \Phi(\mathbf{s}_i), \Phi(\mathbf{x}) \rangle + b = \sum_{i=1}^{N_s} \alpha_i y_i K(\mathbf{s}_i, \mathbf{x}) + b \quad (5.38)$$

sendo que o resultado final do classificador é visto por  $\text{sign}(f(x))$ .

Desta forma, com uma escolha adequada do *kernel*, é possível transformar um problema de separação não-linear num problema de separação linear.

## 5.6 Kernels

A função da utilização do *kernel* é a de permitir realizar as operações no espaço de entrada em vez do espaço de características, potencialmente de dimensão elevada.

Nem todas as funções podem ser usadas como *kernel*. As funções que podem ser usadas como *kernel* devem satisfazer as condições de Mercer, (Courant & Hilbert, 1953; Vapnik, 1998), (Anexo C).

Se uma determinada função  $K$  é definida positiva, isto é cumpre as condições de Mercer, então é garantida a existência de um mapeador  $\Phi$  tal que  $K(x, y) = \langle \Phi(x), \Phi(y) \rangle$ .

De seguida apresentam-se alguns dos *kernels* mais usados.

### 5.6.1 Polinomial

O mapeamento polinomial é um método habitualmente usado para realizar a modelação não linear. Pode ser definido por:

$$K(x, x') = \langle x, x' \rangle^d \quad (5.39)$$

$$K(x, x') = (\langle x, x' \rangle + 1)^d \quad (5.40)$$

A segunda versão é preferível à primeira pois evita que a Hessiana se anule. O valor de  $d$  relaciona-se com a dimensão do espaço de características.

### 5.6.2 Função Gaussiana de Base Radial

Consiste num mapeador do tipo:

$$K(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right) \quad (5.41)$$

A utilização de um kernel deste tipo obriga à determinação dos centros dos subconjuntos (Gunn, 1998) o que é realizado através de métodos de *clustering*. Uma das vantagens da sua utilização nas SVMs é que essa tarefa é implícita, uma vez que cada vector de suporte contribui para uma função Gaussiana local em que o centro é o ponto definido pelo padrão de treino. No caso do algoritmo *Kernel-Adatron* é vulgar usar-se esta função de *kernel* (Rodrigues, 2008).

### 5.6.3 Função Exponencial de Base Radial

Toma a forma de:

$$K(x, x') = \exp\left(-\frac{\|x - x'\|}{2\sigma^2}\right) \quad (5.42)$$

Produz uma solução linear composta o que pode ser vantajoso em casos em que as descontinuidades são aceitáveis (Gunn, 1998).

### 5.6.4 Perceptron Multicamada

O *kernel perceptron* multicamada pode ser representado por:

$$K(x, x') = \tanh(\rho \langle x, x' \rangle + \vartheta) \quad (5.43)$$

Em que  $\rho$  e  $\vartheta$  representam os parâmetros de escala e *offset*, respetivamente. Os vetores de suporte correspondem à primeira camada e os pesos aos multiplicadores de Lagrange (Gunn, 1998).



### 5.6.5 Série de Fourier

O kernel definido no intervalo  $\left[-\frac{\pi}{2}, \frac{\pi}{2}\right]$  pode ser representado por:

$$K(x, x') = \frac{\sin\left(N + \frac{1}{2}\right)(x - x')}{\sin\left(\frac{1}{2}(x - x')\right)} \quad (5.44)$$

Considerado como a expansão de dimensão  $2N + 1$  no espaço de características.

A capacidade de regularização deste *kernel* é reduzida pelo que poderá não representar uma boa escolha (Gunn, 1998).

### 5.6.6 Kernel Aditivo

São obtidos pela soma de outros *kernels*. Tomam a forma de:

$$K(x, x') = \sum_i K_i(x, x') \quad (5.45)$$

A possibilidade de realizar a soma advém do facto de a soma de duas funções definidas positivas ser também ela uma função definida positiva.

### 5.6.7 Produto Tensorial

Permite obter um *kernel* multidimensional. Pode ser obtido pelo produto de diversos *kernels*:

$$K(x, x') = \prod_i K_i(x_i, x'_i) \quad (5.46)$$

## 5.7 Seleção do Kernel

A seleção do *kernel* mais adequado ao problema não é, geralmente, determinística. Os métodos determinísticos exigem a estimativa do raio da esfera que envolve os dados no espaço de características não linear (Rodrigues, 2008).

A forma mais prática e habitualmente usada na seleção consiste na inclusão de vários mapeamentos e a seleção é realizada em função do desempenho de cada um. Os testes comparativos devem ser

suportados por mecanismos como a validação cruzada para avaliar a capacidade de generalização de cada *kernel* (Gunn, 1998).

Para os testes realizados no âmbito deste trabalho o *kernel* que apresentou melhor desempenho foi o Gaussiano de base radial descrito na subsecção 5.6.2.

## 5.8 Sugestão de um Método de Segmentação das Imagens Fetais

A SVM foi usada para realizar a segmentação das imagens fetais e a identificação dos pontos da medida DCC. Para cumprir o primeiro objetivo, a SVM, foi treinada para assinalar o contorno/corpo do feto e, desta forma, permitir a extração do mesmo com vista à medição da DCC pelos mecanismos descritos nas subsecções 6.6.1, 6.6.2 e 6.6.3. O treino foi realizado com pontos pertencentes ao contorno/corpo do feto e, como tal, considerados como casos positivos e foi treinada com pontos não pertencentes a estas regiões, considerados como casos negativos. As imagens usadas no treino foram anotadas manualmente de acordo com a percepção do contorno/corpo fetal. Para o segundo objetivo foi treinada com pontos pertencentes à região assinalada manualmente como ponto de medida, caso positivo, e com os restantes pontos da imagem, casos negativos.

A partir dos pontos anotados (casos positivos + casos negativos) foi retirado um conjunto de características de acordo com o seguinte modelo (Figura 5.10):

1. Para o pixel em causa (**Pc**) foi definida uma máscara radial híbrida de 60 pixéis de raio cujo valor foi determinado através de testes realizados para tamanhos distintos;
2. A partir de **Pc** foram estabelecidos, para a distância indicada em 1, 24 raios distintos (**r1**, **r2**,...) distribuídos linearmente pela máscara;
3. Para cada raio foram usados, intercaladamente, o valor do pixel (intensidade) e a diferença em termos de intensidade relativamente ao pixel **Pc**. Assim para o primeiro pixel da máscara, **P1**, foi usado o valor da sua intensidade, para o segundo, **P2**, a diferença relativamente ao pixel central, para o terceiro, **P3**, novamente o seu valor e assim sucessivamente até ao pixel limite da máscara. Este procedimento permite obter um espaço de características mais imune às variações de brilho de imagem para imagem mas sem perder informação dos valores diretos dos pixéis que formam a própria imagem. Já que localmente existe uma correlação forte, nos valores dos pixéis, a estratégia de aquisição alternada é adequada.
4. O processo descrito em 3 foi realizado para todos os raios definidos em 2.

O vetor de características resultante toma a forma:

$$V_C = [P_C, P_{1_i}, P_{2_i} - P_C, P_{3_i}, P_{4_i} - P_C, \dots, P_{n-1_i} - P_C, P_{n_i}] \quad (5.47)$$

em que  $i$  representa o índice do raio e  $n$  o comprimento do raio .

O mecanismo usado permite caracterizar a região envolvente através da utilização simultânea de informação absoluta e de variação dos pixels vizinhos relativamente ao pixel central, nas diversas direções. Para além destas características foi também usada a informação de localização do pixel na imagem como forma de permitir a eliminação de classificações positivas de pixels pertencentes a contornos de regiões mais afastadas da região central. Pressupõe-se, neste caso, que de uma forma geral a posição do feto na imagem não variará muito em termos de posição. Relativamente a este aspeto, é importante referir que as regras internacionais para obtenção das imagens fetais com vista à medição da DCC obrigam a um corte sagital, com o feto em posição neutra e a ocupar cerca de 75% da imagem.

Assim sendo, cada ponto usado no treino é caracterizado por um vetor de 842 características.

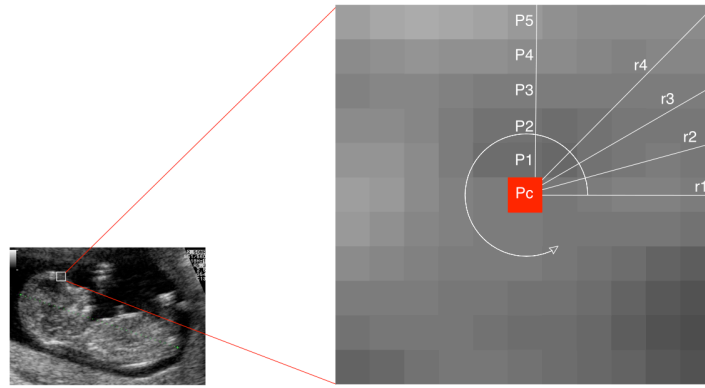


Figura 5.10 – Excerto da máscara radial híbrida usada para a construção do espaço de características. Pc representa o pixel central e P1-P5 uma parte dos pixels para um dos raios usados na extração de características.

### 5.8.1 Análise de Componentes Principais

Para reduzir o espaço de entrada da SVM (características extraídas segundo o processo indicado na secção anterior) e melhorar a capacidade de generalização foi usado o método de Análise de Componentes Principais (PCA) (Jolliffe, 2013). O método permite encontrar um subespaço de representação, de menor ou, no pior dos casos, de igual dimensão ao espaço original, para o qual existe maior separação dos dados. Na prática o método consiste na decomposição da matriz de entrada nos vetores e valores próprios associados. Os vetores próprios correspondem a um novo eixo de representação que garante a máxima variância, ou seja, que descorrelaciona os dados de entrada. A redução da dimensionalidade do espaço de entrada resulta da utilização dos vetores próprios com maior valor próprio associado e que correspondem às componentes que mais contribuem para a

variância dos dados. A Figura 5.11 apresenta um exemplo para uma distribuição dos dados com a indicação dos vetores próprios. Na Figura 5.12 é feita a representação dos dados nas novas coordenadas depois de aplicada a PCA. A aplicação do método ao espaço das 842 características extraídas das imagens de teste permitiu efetuar a redução para um total de 30 características sem comprometer o resultado final. Além disso a capacidade de generalização foi aumentada.




Figura 5.11 – Exemplo de uma distribuição com indicação dos vetores próprios que maximizam a variância.




Figura 5.12 – Representação dos dados anteriores no novo eixo definido pelas componentes principais depois de aplicada a PCA.

### 5.8.2 *Whitening* dos Dados

O procedimento de *whitening* permite melhorar ainda mais a separação dos dados e é amplamente usado em estratégias de *Machine Learning* como o *Deep Learning* (Bengio, Goodfellow, & Courville, 2015). Consiste em utilizar o resultado da transformação do método PCA e efetuar um reescalonamento com o respetivo valor próprio de acordo com:

$$x_{PCA_{white}}^i = \frac{x_{PCA}^i}{\sqrt{\lambda_i}} \quad (5.48)$$

em que  $x_{PCA_{white}}^i$  representa o dado depois de efetuado o *whitening*,  $x_{PCA}^i$  o dado no referencial PCA e  $\lambda_i$  o valor próprio associado a cada vetor próprio encontrado pela PCA. Esta transformação permite obter uma matriz de dados cuja covariância é a matriz identidade, ou seja, as componentes não possuem correlação e possuem variância 1. A Figura 5.13 apresenta o resultado do *whitening* para o exemplo da subsecção 5.8.1.




Figura 5.13 – Resultado do *whitening* aplicado ao exemplo apresentado na subsecção 5.8.1.

O diagrama de blocos da Figura 5.14 descreve sucintamente o processo de segmentação baseado na SVM. A partir de uma imagem de entrada, por aplicação da máscara radial, são retiradas as características primárias da imagem. Estas são processadas por uma PCA *whitening* como forma de encontrar as componentes que mais contribuem para a variância dos dados e incrementar a separabilidade dos mesmos. As componentes principais identificadas são depois usadas pela SVM para realizar a classificação de cada ponto da imagem nas respetivas classes.




Figura 5.14 – Fases do processo de classificação implementado para segmentação das imagens fetais com recurso à SVM.

Os resultados da aplicação da SVM com recurso ao método PCA *whitening* são apresentados e discutidos no capítulo 6.

## 5.9 Conclusão

Neste capítulo foram introduzidos os conceitos que estão na base de formulação das SVMs. Pelo facto de minimizarem o risco estrutural, as SVMs, permitem melhorar a capacidade de generalização e, como tal, apresentar melhores resultados que outras estratégias habitualmente usadas (e.g. redes neuronais). Esta será, porventura, a característica mais diferenciadora e que contribui para o seu sucesso nas diversas aplicações em que são usadas. Esta observação foi comprovada por comparação com os resultados da implementação de uma rede neuronal *MultiLayer Perceptron* (MLP). Por outro lado, é possível, pela utilização de uma função adequada (*kernel*) transformar um problema de separação não linear num problema de separação linear com vantagens óbvias para os algoritmos de otimização. Foram também apresentadas as estratégias usadas para melhorar a separabilidade dos dados do espaço de características usados, decorrelacionando-os, e, simultaneamente, reduzir a dimensionalidade do problema (PCA *whitening*) melhorando o desempenho da própria SVM.

Os resultados obtidos pela aplicação da SVM ao problema da segmentação das imagens fetais são apresentados e discutidos no capítulo 6.

## 6. ANÁLISE E DISCUSSÃO DE RESULTADOS

### 6.1 Introdução

Neste capítulo são apresentados e discutidos os resultados obtidos pela aplicação dos métodos descritos nos capítulos anteriores na segmentação das imagens fetais com vista à extração automática da medida da DCC. Os métodos foram testados num conjunto de 20 imagens selecionadas por apresentarem características de brilho, contraste, ruído, morfologia e posição do feto variadas. Esta heterogeneidade permitiu avaliar a capacidade de generalização dos métodos usados e encontrar os seus pontos fortes e fragilidades. As imagens usadas não foram submetidas, intencionalmente, a qualquer pré-processamento. Para cada método apresentado foi avaliado o desempenho em função da parametrização e, em alguns deles, sugeridos mecanismos para diminuir a dependência destes, melhorando o aspeto da generalização.

Por fim são sugeridas estratégias para a extração da medida da DCC.

### 6.2 *Fuzzy Clustering*

As metodologias apresentadas no capítulo 3 foram aplicadas às imagens fetais do primeiro trimestre usadas na medição da DCC. Os resultados que a seguir se expõem referem-se a um conjunto de três imagens selecionadas com critério de entre um conjunto mais vasto. Os critérios usados na seleção foram:

- Obedecer às normas definidas pelas organizações mundiais que regulam a atividade obstétrica;
- Apresentarem uma posição fetal distinta;
- Apresentar artefactos ou zonas “vazias” em regiões de tecidos;
- Apresentar zonas de junção entre o feto e as paredes do útero;
- Apresentar diferenças ao nível do contraste e da intensidade;

As imagens que recolheram a nossa preferência estão representadas na Figura 6.1.

As experiências foram realizadas em ambiente Matlab R2014b, e o classificador foi configurado para 2 *clusters* e  $m = 2$ .



Figura 6.1 – Imagens selecionadas para avaliação do desempenho das metodologias de *Fuzzy Clustering*.

### 6.2.1 FCM

O FCM realiza o agrupamento das classes em função da distância de cada elemento do espaço de características de entrada ao centro de cada classe. O resultado é uma matriz de partição difusa que traduz o nível de confiança na pertença de um dado ponto a cada classe. A Figura 6.2 mostra o resultado da partição para uma das imagens usadas e pretende ilustrar que nem todos os pontos são atribuídos com elevada confiança ao respetivo *cluster*.



Figura 6.2 – Partições resultantes da aplicação do método FCM. O nível de intensidade representa o grau de pertença.

Apesar de o mesmo pixel poder ser atribuído a ambos os *clusters*, ainda que, possivelmente com graus de pertença distintos, é sempre necessário atribuir o ponto apenas a um deles. Atendendo a que o espaço de características usado para a realização da segmentação deriva da intensidade do pixel, pontos cuja intensidade seja próxima da do centro do *cluster* tomam um grau de pertença elevado a esse mesmo *cluster*, enquanto que pontos cuja diferença de intensidade relativamente ao protótipo seja elevada verão atribuído um grau de pertença reduzido. Nestes casos, a separação é simples de realizar, pelo que a decisão baseada no máximo grau de pertença apresenta resultados satisfatórios. No entanto, este mecanismo tende a ser insatisfatório nos casos em que os pontos apresentam graus de pertença semelhantes a ambos os grupos ou nos casos em que os pontos estão fortemente corrompidos por ruído. Tanto num caso como no outro podem ocorrer atribuições incorretas. Atendendo a que as imagens fetais apresentam um nível de ruído significativo, em muitos casos com



perda de representação de regiões relevantes, o método não será indicado neste tipo de aplicação. Os resultados obtidos pela aplicação do método FCM às três imagens de referência representadas na Figura 6.1 podem ser vistos na Figura 6.3 e confirmam esta conclusão.



Figura 6.3 – Resultados da aplicação do método FCM definido para 2 *clusters* e  $m=2$ .

Uma das formas de melhorar este resultado consiste na incorporação da informação espacial no processo de *clustering*, por forma a correlacionar cada pixel com os pixels envolventes e, desta forma, encontrar uma partição final que depende, simultaneamente, do espaço de características e da informação contida nos pixels vizinhos. Estes mecanismos foram descritos detalhadamente nos pontos 3.3 e 3.4 deste documento.

#### 6.2.2 FCMV

O primeiro método usado para melhorar o resultado da partição FCM foi o FCMV. Tal como referido em 3.3, este método consiste em utilizar o próprio resultado do FCM para encontrar uma nova partição que contenha alguma informação dos pixels envolventes. Para tal estabeleceram-se janelas de vizinhança no intervalo  $[3,20]$  e a decisão é baseada na observação do somatório dos graus de pertença dos elementos da janela a cada *cluster*.

Os resultados obtidos para janelas variáveis no intervalo  $[3,8]$  são apresentados na Figura 6.4, Figura 6.5 e Figura 6.6. As imagens correspondentes às restantes janelas não são apresentadas por corresponderem a segmentações com elevado nível de perda de detalhe.

Estes resultados permitem retirar duas conclusões importantes. Como seria de esperar, a dimensão da janela usada afeta o resultado da classificação. Janelas com dimensão superior têm a virtude de reduzir/eliminar pequenas áreas de pixels mal classificados pelo FCM, mas afetam também a classificação dos pixels nas regiões fronteira. Este aspeto está bem representado na Figura 6.5. Por outro lado, janelas reduzidas, não manifestam este efeito, mas evitam o preenchimento das regiões mal classificadas (e.g. buracos).

Outro aspecto relevante é a influência da dimensão da janela no detalhe da segmentação. O aumento da janela contribui para a suavização do contorno mas conduz à perda de detalhe no mesmo (ver Figura 6.5). Este efeito pode ser atenuado pela ponderação das contribuições efetivas de cada componente (vizinhança/grau de pertença), tal como usado nos métodos  $FCMS_1$ ,  $FCMS_2$ ,  $FCMS_{2m}$ ,  $FCMS_3$  e GKFCM.




Figura 6.4 – Resultado da segmentação baseada no FCMV com decisão baseada na vizinhança para janelas de 3x3 a 8x8 (imagem superior esquerda corresponde à janela 3x3 e a imagem inferior direita a 8x8. A dimensão aumenta da esquerda para a direita e de cima para baixo).




Figura 6.5 - Resultado da segmentação baseada no FCMV com decisão baseada na vizinhança para janelas de 3x3 a 8x8 (imagem superior esquerda corresponde à janela 3x3 e a imagem inferior direita a 8x8. A dimensão aumenta da esquerda para a direita e de cima para baixo).




Figura 6.6 – Resultado da segmentação baseada no FCMV com decisão baseada na vizinhança para janelas de 3x3 a 8x8 (imagem superior esquerda corresponde à janela 3x3 e a imagem inferior direita a 8x8. A dimensão aumenta da esquerda para a direita e de cima para baixo).

### 6.2.3 FCMS<sub>1</sub>

A informação espacial do método FCMV é vista apenas pela observação da partição na vizinhança. Isto significa que a própria partição não é otimizada pela influência simultânea das componentes espacial e intensidade. Os métodos designados no ponto 3.4 deste documento por FCMS<sub>1</sub>, FCMS<sub>2</sub>, FCMS<sub>2m</sub> e FCMS<sub>3</sub> são alternativas ao método FCMV e permitem obter uma partição difusa que integra ambas as contribuições. Na prática, o método FCMS<sub>1</sub> é muito semelhante ao anterior, pois a partição final é recalculada a partir da combinação da partição inicial FCM conjugada com uma partição espacial de vizinhança. No entanto, a contribuição de cada uma é pesada pelos parâmetros  $p$  e  $q$  da Equação (3.9), o que permite melhorar o comportamento do segmentador com o aumento da janela de vizinhança.

Os resultados obtidos pela aplicação do método às imagens da Figura 6.1 estão representados na Figura 6.7. Foram usados os mesmos pesos para a informação espacial e informação de intensidade,  $p = q = 1$ . As imagens da primeira linha usaram uma vizinhança 3x3 e as da segunda 20x20.

Ao contrário do método apresentado no ponto 3.3, observa-se que o aumento da janela não implica uma alteração significativa no resultado da segmentação, mesmo para regiões de interface ou fronteira. Este aspeto está diretamente relacionado com a possibilidade de atribuir pesos a ambas as características (intensidade e espaço). Desta forma é possível regular a contribuição de cada função na partição final, podendo dar maior importância a uma ou a outra componente. Os resultados para a variação do peso da contribuição espacial no resultado de *clustering* são apresentados na Figura 6.8.




Figura 6.7 – Resultados da aplicação do método  $FCMS_1$  para janelas 3x3 (cima) e de 20x20 (baixo),  $p=q=1$ .

O aumento do peso da contribuição espacial não contribui para uma alteração significativa do resultado. A justificação encontra-se na Equação (3.9). Apesar do aumento de  $q$  (peso da componente espacial do método), a contribuição espacial para um pixel é atenuada pela contribuição global do conjunto dos *clusters*.




Figura 6.8 – Variação do resultado da segmentação com o aumento do peso da informação espacial. Da esquerda para a direita  $q=2$ ,  $q=3$  e  $q=4$ , respetivamente.

#### 6.2.4 FCMS<sub>2</sub> e FCMS<sub>2m</sub>

Ao contrário de FCMS<sub>1</sub> e FCMV, os restantes métodos de FC apresentados incluem no próprio processo de otimização as duas componentes. Este aspeto está bem evidenciado nas equações (3.13), (3.21) e (3.24) onde se encontram representados na função de custo os dois termos que contribuem para a definição da partição: intensidade e espaço. No caso de FCMS<sub>2</sub> e FCMS<sub>2m</sub> a contribuição espacial é pesada pelo parâmetro  $\alpha$  e é dependente da distância entre cada ponto ao valor médio ou à mediana, respetivamente, do conjunto de pontos que constituem a janela. A utilização da mediana é mais eficiente quando a imagem é influenciada por ruído do tipo impulsional e a média nos casos de ruído Gaussiano. No caso das imagens fetais os resultados não são significativamente afetados pela escolha de um ou outro filtro, na medida em que as imagens são afetadas essencialmente por ruído *speckle*.

O resultado da aplicação deste último método, usando filtro de média e de mediana, estão apresentados na Figura 6.9 e Figura 6.10, respetivamente. As imagens obtidas referem-se à utilização de janelas de  $5 \times 5$  e  $10 \times 10$  com  $\alpha = 5$ .

O método é mais sensível à dimensão da janela. Note-se que para valores de  $\alpha$  constantes, a variação da região de vizinhança influencia significativamente o resultado da partição. Este aspeto pode ser justificado pelo facto de a partição final estar dependente da distância de cada ponto ao centro do *cluster* e à vizinhança da imagem filtrada (média ou mediana), sendo que esta última tem como efeito a suavização da mesma. A utilização de janelas de dimensão elevada contribui para a perda de detalhe, essencialmente do contorno, mas permite eliminar alguns artefactos.




Figura 6.9 – Resultado da aplicação do método FCMS<sub>2</sub> com informação espacial para janelas  $5 \times 5$  (cima) e  $10 \times 10$  (baixo).  $\alpha = 5$ .




Figura 6.10 – Resultados da aplicação do método  $FCMS_{2m}$  para janelas  $5 \times 5$  (cima) e  $10 \times 10$  (baixo),  $\alpha = 5$ .

A variação do parâmetro  $\alpha$  permite controlar o peso da componente filtrada relativamente à imagem original. Os efeitos do seu aumento são semelhantes aos do aumento da dimensão da janela mas fazem-se sentir com uma intensidade menor (Figura 6.11 e Figura 6.12). A influência do seu aumento na otimização da respetiva função de custo, quer na partição difusa quer na variação dos centros, é sempre vista em termos relativos. Este aspeto é mais evidente se analisarmos as equações (3.14) e (3.15). Na prática, a alteração da janela contribui de forma direta para um aumento significativo da distância dos pontos aos valores filtrados pelo que o resultado da otimização acaba por ser mais influenciado pela vizinhança que propriamente pelo peso relativo atribuído a esta componente.




Figura 6.11 – Resultado de  $FCMS_2$  para janelas  $5 \times 5$  e  $\alpha = 3$  (cima) e  $\alpha = 10$  (baixo).

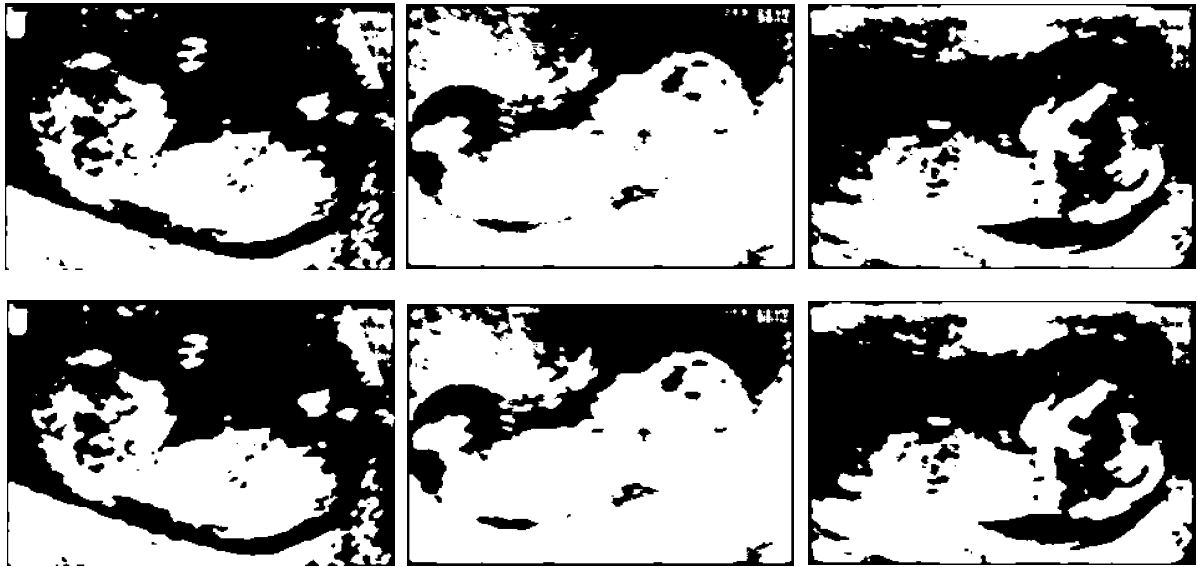


Figura 6.12 – Resultado do método  $FCMS_{2m}$  para janela  $5 \times 5$  e  $\alpha = 3$  (cima) e  $\alpha = 10$  (baixo).

#### 6.2.5 $FCMS_3$

Um dos problemas do método anterior reside no facto de estabelecer um peso igual ( $\alpha$ ) para todos os pixels da janela, independentemente da distância a que este se encontra do pixel central o que, intuitivamente, é pouco razoável. Em sentido contrário, o  $FCMS_3$ , permite atribuir pesos diferentes em função da posição relativa de cada pixel, sendo que a influência de cada um diminui com o aumento da distância. O resultado é uma matriz de similaridade que permite incorporar a relação espacial e a relação de intensidades locais com pesos condicionados pela distância ao centro da janela usada, tal como apresentado nas equações (3.17) e (3.18). Por outro lado a inclusão dos parâmetros  $\lambda_s$  e  $\lambda_G$  permite ajustar de forma independente a influência da componente espacial e de intensidade, respetivamente. O resultado, para janelas de  $3 \times 3$  e  $5 \times 5$ , está representado na Figura 6.13. Uma observação atenta desta figura permite concluir que o aumento da dimensão da janela contribui para a redução dos artefactos da imagem e, consequentemente, para a melhoria do segmentador nas regiões mais afetadas por ruído. Por outro lado, isto é conseguido sem afetar o detalhe da imagem. A avaliação da influência de  $\lambda_G$  e  $\lambda_s$  revela um efeito semelhante ao do aumento da janela, ou seja, o detalhe é preservado com o seu aumento. Para uma janela de dimensão fixa, o seu incremento, permite aumentar o peso relativo dos pixels vizinhos no pixel central, pelo que a medida de similaridade,  $S_{ij}$  (Equação (3.16)), será mais influenciada pelos pixels periféricos da janela (ainda que com um peso inferior aos mais próximos). Apesar disso, a segmentação não é significativamente afetada e o detalhe dos contornos, mesmo para regiões de proximidade, mantido. Estes aspetos são uma mais valia do

método e confirmam a sua robustez. A variação do resultado da segmentação com a variação do valor dos parâmetros referidos está representada na Figura 6.14 e Figura 6.15.

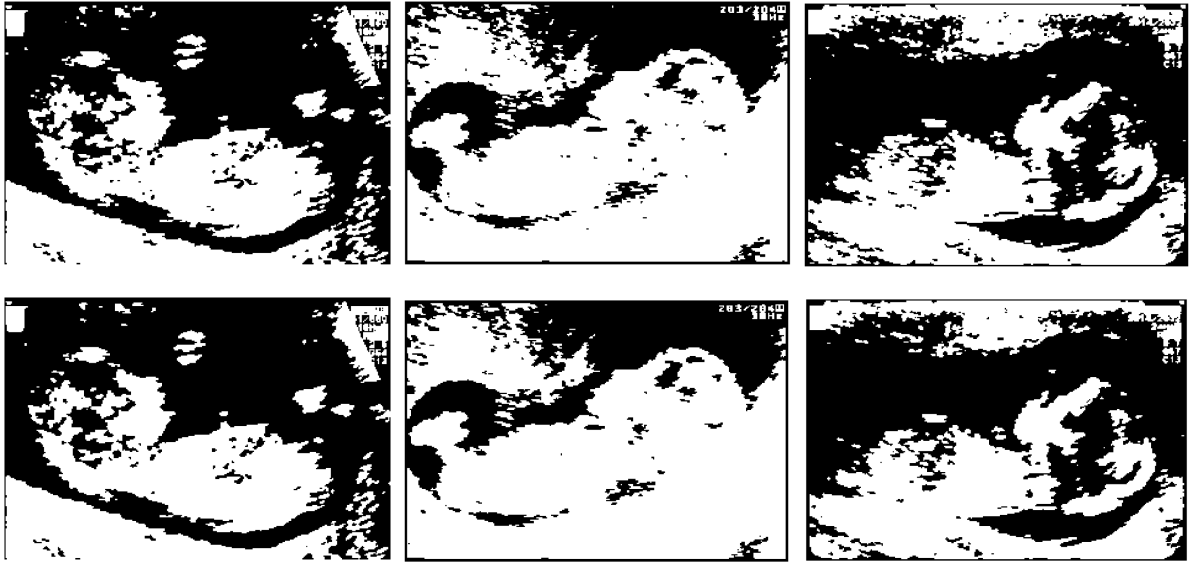


Figura 6.13 – Resultado da segmentação segundo o método  $FCMS_3$  com  $\lambda_s = 0.5$ ,  $\lambda_o = 3$  e janela  $3 \times 3$  (cima) e  $5 \times 5$  (baixo).




Figura 6.14 – Variação do resultado da segmentação com a variação do parâmetro  $\lambda_o$ , ( $\lambda_s = 3$  e  $\lambda_o = \{1, 3, 6\}$ , de cima para baixo).






Figura 6.15 – Variação do resultado da segmentação com a variação do parâmetro  $\lambda_s$ , ( $\lambda_o = 0.5$  e  $\lambda_s = \{1, 3, 6\}$ , de cima para baixo).

#### 6.2.6 GKFCM

O GKFCM tem como principal virtude a quase ausência de parametrização. Os métodos anteriores possuem diversas parametrizações, cuja escolha inadequada pode comprometer o resultado da segmentação. Naturalmente, que estes parâmetros podem ser encontrados por intermédio de uma otimização que permitisse ajustar os parâmetros a um determinado conjunto de imagens. Contudo, isto exigiria esforço computacional.

O GKFCM apenas necessita de configurar a dimensão da janela do filtro a usar. Tal como referido na secção 3.4.4 foram aplicadas versões do filtro baseadas na média e na mediana. Os resultados obtidos da aplicação do GKFCM às imagens de referência indicadas na Figura 6.1 para janelas de  $5 \times 5$  e filtro de média e de mediana são apresentados na Figura 6.16 e Figura 6.17, respetivamente.



Figura 6.16 – Resultado da segmentação pelo método GKFCM com filtro de média e janela  $5 \times 5$ .



Figura 6.17 – Resultado da segmentação do GKFCM com filtro mediana e janela  $5 \times 5$ .

É notória a diferença nos resultados obtidos pela aplicação GKFCM com filtro de média e GKFCM com filtro de mediana, principalmente na imagem central. O filtro de mediana é mais robusto que o de média, em especial nos casos em que existam na janela poucos pixels com ruído. Ao contrário da média, os *outliers* não afetam significativamente o resultado da mediana. Além disso a mediana é mais eficiente na preservação das regiões de separação contribuindo para a manutenção do detalhe das interfaces.

Face aos resultados obtidos pela aplicação dos diversos métodos FCM é importante referir que a inclusão da informação local de vizinhança permite melhorar o resultado da segmentação pela regularização da influência dos pixels com ruído. No entanto, nos casos em que a informação local não é suficiente, as correções introduzidas são incapazes de realizar a classificação de forma correta. Estes casos são notórios na região do crânio do feto, especialmente nas imagens 1 e 3. Nestes casos, algumas regiões, estão de tal forma corrompidas que grande parte dos pixels confundem-se com o líquido amniótico que envolve o feto. Para um humano a regularização do contorno é relativamente simples de realizar pois possui informação relativa à forma do feto que o classificador FC não possui.

### 6.3 Validação dos Métodos de *Fuzzy Clustering*

Com o objetivo de avaliar o desempenho de cada método de FC usado na segmentação das imagens fetais referentes ao primeiro trimestre de gestação, foram usados os coeficientes referidos na secção

3.5. Os cálculos realizados por CP, EP, FS, XB e GG destinam-se a avaliar o resultado da partição difusa por medição da compactação e/ou separação. Já o coeficiente ES é uma medida direta da qualidade do classificador, pois permite avaliar, por comparação com a segmentação ótima, o resultado obtido por cada método. A classificação ótima foi obtida manualmente sobre as imagens da Figura 6.1 tendo em atenção a percepção da imagem pelo operador humano. A Tabela 6.1, a Tabela 6.2 e a Tabela 6.3 contêm os resultados, respetivamente, para a imagem 1, 2 e 3 da Figura 6.1.

A primeira conclusão a retirar da análise dos dados apresentados nas tabelas é que não existe uma relação direta entre ES e os restantes coeficientes de validação. Nem sempre o método que apresenta os melhores coeficientes CP, EP, XB e GG é o método que apresenta a melhor taxa de acertos, pelo que a avaliação incidirá essencialmente sobre a ES.

Tabela 6.1 – Valores dos coeficientes de validação obtidos para a primeira imagem da Figura 6.1. Nos métodos com dependência da vizinhança foi usada uma janela 5x5. Para FCMS<sub>1</sub> foram usados os mesmos pesos  $p = q = 2$ . Em FCMS<sub>2</sub> e FCMS<sub>2m</sub> foi usado  $\alpha = 5$ . Em FCMS<sub>3</sub> foi usado  $\lambda_s = 0.5$  e  $\lambda_o = 3$ .

	CP	EP	FS	XB	GG	ES
<b>FCM</b>	0.8427	0.1137	-4.5294e+07	0.0844	47.4968	0.6622
<b>FCMV</b>	-	-	-	-	-	0.6685
<b>FCMS<sub>1</sub></b>	0.9608	0.0280	-4.9199e+07	0.1010	48.2455	0.6592
<b>FCMS<sub>2</sub></b>	0.8415	0.1152	-2.5609e+07	0.1276	53.4069	0.6851
<b>FCMS<sub>2m</sub></b>	0.8420	0.1147	-2.8643e+07	0.1214	53.0382	0.6865
<b>FCMS<sub>3</sub></b>	0.8445	0.1126	-3.4939e+07	0.1089	51.6510	0.6738
<b>GKFCM</b>	0.7272	0.1823	-9.5202e+06	0.1637	84.4961	0.7386
<b>GKFCM<sub>m</sub></b>	0.7260	0.1834	-1.0406e+07	0.1510	64.9644	<b>0.7451</b>

Tabela 6.2 - Valores dos coeficientes de validação obtidos para a segunda imagem da Figura 6.1. Nos métodos com dependência da vizinhança foi usada uma janela 5x5. Para FCMS<sub>1</sub> foram usados os mesmos pesos  $p = q = 2$ . Em FCMS<sub>2</sub> e FCMS<sub>2m</sub> foi usado  $\alpha = 5$ . Em FCMS<sub>3</sub> foi usado  $\lambda_s = 0.5$  e  $\lambda_o = 3$ .

	CP	EP	FS	XB	GG	ES
<b>FCM</b>	0.8449	0.1121	-4.7198e+07	0.0824	47.6933	0.7948
<b>FCMV</b>	-	-	-	-	-	0.8108
<b>FCMS<sub>1</sub></b>	0.9634	0.0263	-5.6142e+07	0.0927	47.0856	<b>0.8174</b>
<b>FCMS<sub>2</sub></b>	0.8540	0.1071	-3.6975e+07	0.1086	54.3489	0.8024
<b>FCMS<sub>2m</sub></b>	0.8571	0.1048	-4.5461e+07	0.0969	53.7707	0.8170
<b>FCMS<sub>3</sub></b>	0.8552	0.1055	-4.9525e+07	0.0890	52.1224	0.8115
<b>GKFCM</b>	0.7343	0.1778	4.3063e+07	0.2879	92.9843	0.7694
<b>GKFCM<sub>m</sub></b>	0.7403	0.1750	5.5036e+08	0.2208	90.1414	0.8116

Tabela 6.3 – Valores dos coeficientes de validação obtidos para a terceira imagem da Figura 6.1. Nos métodos com dependência da vizinhança foi usada uma janela 5x5. Para  $FCMS_1$  foram usados os mesmos pesos  $p = q = 2$ . Em  $FCMS_2$  e  $FCMS_{2m}$  foi usado  $\alpha = 5$ . Em  $FCMS_3$  foi usado  $\lambda_s = 0.5$  e  $\lambda_g = 3$ .

	CP	EP	FS	XB	GG	ES
<b>FCM</b>	0.8324	0.1196	-3.0088e+07	0.0941	42.9652	0.6295
<b>FCMV</b>	-	-	-	-	-	0.6314
<b>FCMS<sub>1</sub></b>	0.9555	0.0319	-3.4859e+07	0.1089	43.4114	0.6283
<b>FCMS<sub>2</sub></b>	0.8317	0.1211	-1.8265e+07	0.1281	46.4283	0.6459
<b>FCMS<sub>2m</sub></b>	0.8313	0.1209	-2.0831e+07	0.1199	45.6709	0.6553
<b>FCMS<sub>3</sub></b>	0.8330	0.1192	-2.5875e+07	0.1061	44.4568	0.6393
<b>GKFCM</b>	0.7448	0.1719	1.7748e+07	0.2359	81.2366	0.7153
<b>GKFCM<sub>m</sub></b>	0.7433	0.1731	2.8259e+08	0.2522	88.3467	<b>0.7194</b>

Apesar de a ES apresentar valores muito próximos para todos os classificadores, de uma forma geral, os métodos com informação espacial apresentam melhores resultados face ao método clássico FCM, com acréscimos de acertos mínimo de cerca de 2% e máximo de 9%, observados face ao melhor classificador para as experiências realizadas.

Tabela 6.4 – Valor médio da ES considerando os resultados obtidos no conjunto das 3 imagens para cada método de FC.

	FCM	FCMV	FCMS <sub>1</sub>	FCMS <sub>2</sub>	FCMS <sub>2m</sub>	FCMS <sub>3</sub>	GKFCM	GKFCM <sub>m</sub>
<b>ES médio</b>	0.6955	0.7035	0.7016	0.7111	0.7196	0.7124	0.7411	<b>0.7587</b>

Por outro lado, não foi possível retirar conclusões perentórias acerca do melhor classificador. As observações demonstram que o resultado do método está dependente da entrada (imagem). É, no entanto, possível indicar que, em termos médios e **face às condições usadas nos testes**, designadamente no que se refere à parametrização, o método GKFCM apresenta os melhores resultados no conjunto das imagens selecionadas (ver Tabela 6.4), o que permite afirmar que o classificador possui maior capacidade de generalização. Um bom indicador deste aspeto é o facto de ter sido o melhor classificador em duas das três imagens e no caso em que não o foi, a taxa de acertos se encontrar muito próxima do vencedor. Um outro aspeto importante é que o GKFCM requer a configuração de um menor número de parâmetros, pelo que a sua utilização é simplificada.

## 6.4 Contornos Ativos

Tal como descrito no capítulo 4 os métodos de contornos ativos têm apresentado bons resultados na segmentação de imagens médicas o que *per si* é um argumento forte para justificar a sua utilização no âmbito deste trabalho. No mesmo capítulo foi apresentada a *framework* LS e que é uma ferramenta matemática que permite reduzir e simplificar o tratamento matemático inerente ao processo de evolução da curva. Foi também apresentado um método de contornos ativos que, contrariamente aos métodos habituais, não usa o gradiente da imagem para procurar o contorno que minimiza uma função de custo. Este aspeto é bastante relevante quando se trata de imagens de ultrassons, na medida em que estas são afetadas de forma muito significativa com ruído, o que pode afetar o processo de convergência.

O método descrito na secção 4.4 foi aplicado às imagens fetais selecionadas para avaliação das metodologias e que se encontram representadas na Figura 6.1. Foram usadas duas estratégias distintas para obter a FLS inicial. A primeira consistiu em usar uma FLS pré-definida que foi variada para avaliar o comportamento do segmentador em função do LS inicial usado. A segunda consistiu em usar o resultado da partição difusa do método descrito na secção anterior com o melhor resultado como inicialização. A ideia subjacente é que o resultado da segmentação difusa seja uma aproximação razoável da segmentação final e, como tal, a convergência do LS para o contorno final será realizada rapidamente. Atendendo ao princípio subjacente ao método Chan-Vese é expectável alterações na classificação final por forma a minimizar a função de custo associada. Os testes realizados incluíram ainda a avaliação do resultado com a variação dos parâmetros que compõem o modelo Chan-Vese, designadamente  $\lambda_1$ , o parâmetro de controlo do peso da região interior ao LS zero,  $\lambda_2$ , o parâmetro de controlo do peso da região exterior ao LS zero e  $\mu$ , o parâmetro de controlo do peso do comprimento da curva, o próprio LS zero.

A Figura 6.18, Figura 6.19 e Figura 6.20 apresentam os resultados da segmentação em função do LS inicial usado. Foram usados pesos idênticos para as contribuições das regiões interiores e exteriores ao LS ( $\lambda_1 = 1, \lambda_2 = 1$ ). Tal como esperado o resultado está dependente da FLS usada (dado que a evolução da curva é um problema de valor inicial), sendo que os melhores resultados foram obtidos para a utilização da segmentação fornecida pelo método GKFCM como inicialização da FLS. Neste último caso, note-se, que o resultado não varia significativamente, comparativamente à segmentação inicial, durante o processo iterativo de evolução da interface, o que significa que o algoritmo converge mais rapidamente para um estado estacionário. Por outro lado, de acordo com a Figura 6.18 e Figura

6.19, é observável que a escolha de um LS inicial que abranja toda a imagem é conveniente e permite evoluir a curva para um resultado mais próximo do desejável num menor número de iterações (mesmo após 1000 iterações o resultado obtido para a evolução do LS da Figura 6.18 ainda se encontra em processo de convergência, ver Figura 6.21).




Figura 6.18 - Evolução do LS zero (curva a vermelho) a cada 30 iterações de execução. A imagem do topo à esquerda apresenta o LS inicial usado e a imagem inferior à direita o resultado após 150 iterações, com  $\mu = 0.01 \times 255^2$ ,  $\lambda_1 = 1.0$  e  $\lambda_2 = 1.0$ .  $\lambda_1$  representa o peso atribuído à região interior do LS,  $\lambda_2$  o peso atribuído à região exterior e  $\mu$  o peso atribuído ao comprimento do LS zero.

O resultado obtido pela inicialização baseada na segmentação fornecida pelo GKFCM está muito próximo do obtido por aplicação direta do próprio GKFCM. Naturalmente que, tendo apenas em consideração o custo computacional do método Chen-Vese, a utilização do LS fornecido pelo GKFCM permite a convergência mais rapidamente. No entanto, se atendermos ao custo de desempenho do método GKFCM para obtenção da função inicial, este resultado não é líquido pois exige um tempo de computação (para um erro aceitável) que não é compensado pela redução do número de iterações necessárias para fazer convergir a curva para o contorno (comparado com o resultado obtido por aplicação do LS inicial da Figura 6.19).

Outro aspeto relevante é a perda de regiões que deveriam estar incluídas na região interna do contorno no decorrer do processo iterativo. A Figura 6.19 e a Figura 6.20 apresentam perda de pixels da região interna ao contorno em algumas regiões da imagem (e.g. cabeça do feto). Uma forma de contornar esta situação consiste em aumentar o peso atribuído à área interior ao LS zero ( $\lambda_1$ ). O aumento do peso  $\lambda_1$  implica a diminuição do valor médio necessário na região interna da interface para minimizar a função de custo, pelo que será expectável que alguns dos pixels próximos mas com intensidades

próximas do *background* possam ser incluídos na região interna (este comportamento depende do tipo de imagem, pelo que esta afirmação refere-se à imagem em estudo).




Figura 6.19 - Evolução do LS zero (curva a vermelho) a cada 30 iterações de execução. A imagem do topo à esquerda apresenta o LS inicial usado e a imagem inferior à direita o resultado após 150 iterações, com  $\mu = 0.01 \times 255^2$ ,  $\lambda_1 = 1.0$  e  $\lambda_2 = 1.0$ .  $\lambda_1$  representa o peso atribuído à região interior do LS,  $\lambda_2$  o peso atribuído à região exterior e  $\mu$  o peso atribuído ao comprimento do LS zero.




Figura 6.20 - Evolução do LS zero (curva a vermelho) a cada 30 iterações de execução. A imagem do topo à esquerda apresenta o LS inicial usado (obtido por aplicação do método GKFCM) e a imagem inferior à direita o resultado após 150 iterações, com  $\mu = 0.01 \times 255^2$ ,  $\lambda_1 = 1.0$  e  $\lambda_2 = 1.0$ .  $\lambda_1$  representa o peso atribuído à região interior do LS,  $\lambda_2$  o peso atribuído à região exterior e  $\mu$  o peso atribuído ao comprimento do LS zero.






Figura 6.21 – Resultado da evolução do LS da Figura 6.18 após 1000 iterações.

As experiências seguintes apresentam os resultados obtidos para o mesmo número de iterações do método Chan-Vese com um peso de  $\lambda_1 = 1.8$  e os restantes parâmetros com valor igual ao das simulações anteriores.

Descartando os resultados para a FLS definida pelo círculo simples, Figura 6.22 (cuja convergência não é possível observar para o número de iterações usado no estudo de desempenho), é visível na Figura 6.23 e Figura 6.24 que o resultado final agrega na região interna ao contorno um maior número de pixels (classificados corretamente) que no caso anterior (*e.g.* região do crânio e região caudal). Estes resultados apontam para que seja possível melhorar a segmentação final atribuindo um peso superior à componente da área interna da função de custo associada ao método.




Figura 6.22 - Evolução do LS zero (curva a vermelho) a cada 30 iterações de execução. A imagem do topo à esquerda apresenta o LS inicial usado e a imagem inferior à direita o resultado após 150 iterações, com  $\mu = 0.01 \times 255^2$ ,  $\lambda_1 = 1.8$  e  $\lambda_2 = 1.0$ .  $\lambda_1$  representa o peso atribuído à região interior do LS,  $\lambda_2$  o peso atribuído à região exterior e  $\mu$  o peso atribuído ao comprimento do LS zero.






Figura 6.23 – Evolução do LS zero (curva a vermelho) a cada 30 iterações de execução. A imagem do topo à esquerda apresenta o LS inicial usado e a imagem inferior à direita o resultado após 150 iterações, com  $\mu = 0.01 \times 255^2$ ,  $\lambda_1 = 1.8$  e  $\lambda_2 = 1.0$ .  $\lambda_1$  representa o peso atribuído à região interior do LS,  $\lambda_2$  o peso atribuído à região exterior e  $\mu$  o peso atribuído ao comprimento do LS zero.




Figura 6.24 - Evolução do LS zero (curva a vermelho) a cada 30 iterações de execução. A imagem do topo à esquerda apresenta o LS inicial usado (obtido por aplicação do método GKFCM) e a imagem inferior à direita o resultado após 150 iterações, com  $\mu = 0.01 \times 255^2$ ,  $\lambda_1 = 1.8$  e  $\lambda_2 = 1.0$ .  $\lambda_1$  representa o peso atribuído à região interior do LS,  $\lambda_2$  o peso atribuído à região exterior e  $\mu$  o peso atribuído ao comprimento do LS zero.

Os efeitos do aumento de  $\lambda_1$  são ainda mais evidentes na Figura 6.25. A figura apresenta o resultado da segmentação, após convergência, para valores distintos do peso associado à área interna do contorno, tendo por base a utilização de LS iniciais distintos: função abrangente constituída por diversos círculos e já ilustrada nas figuras anteriores (imagens superiores) e LS inicial definido pelo resultado da segmentação pelo método GKFCM (imagens inferiores). Com o aumento do peso é possível observar um aumento das regiões incluídas no contorno e que, na prática, contribui para uma

melhoria da segmentação, especialmente nas regiões mais afetadas como o crânio ou a região caudal. O aumento de  $\lambda_1$  provoca também uma tendência para a junção de regiões próximas (junção do feto com a parede do útero), o que representa um efeito indesejável na medida em que dificulta a separação dos objetos da imagem.




Figura 6.25 – Resultado da evolução da curva para  $\lambda_1 = 1.0$  ,  $\lambda_1 = 2.0$  e  $\lambda_1 = 4.0$  (da esquerda para a direita) após convergência. As imagens superiores correspondem à utilização da função LS inicial definida pelo conjunto de círculos que abrangem a totalidade da imagem e as imagens inferiores à utilização do resultado do método GKFCM.

Já foi referido que a capacidade de agregação de regiões na região de interesse por via do aumento do peso  $\lambda_1$  é influenciado pelo tipo de imagem. Tome-se como exemplo a Figura 6.26. Ao contrário do caso anterior o aumento do valor da variável contribui para uma redução da área envolvida.




Figura 6.26 – Resultado da evolução do contorno para  $\lambda_1 = 1.0$  ,  $\lambda_1 = 1.8$  e  $\lambda_1 = 2.0$  (da esquerda para a direita).  $\lambda_2 = 1.0$  . Cima: função inicial definida pelo conjunto de círculos; baixo: LS inicial resultado do GKFCM.

A justificação encontra-se no facto de esta imagem apresentar níveis de intensidade superiores, pelo que o equilíbrio entre a área interna e a área externa ao LS é atingido em regiões mais interiores ao contorno ótimo. Elevar o valor de  $\lambda_1$  só irá contribuir para a retração do contorno como forma de equilibrar as duas componentes da função de custo associada à evolução do LS. Neste tipo de imagens é conveniente o uso de um peso superior para a componente externa,  $\lambda_2$ .

O teste do desempenho do modelo face ao aumento de  $\lambda_2$  está representado na Figura 6.27. Nela é possível observar que o aumento do peso da componente exterior permitiu uma segmentação com melhor qualidade que no caso anterior.




Figura 6.27 – Resultado da evolução do contorno para  $\lambda_2 = 1.0$ ,  $\lambda_2 = 1.8$  e  $\lambda_2 = 2.0$  (da esquerda para a direita).

$\lambda_1 = 1.0$ . Cima: função inicial definida pelo conjunto de círculos; baixo: LS inicial resultado do GKFCM.

Estes resultados demonstram a dificuldade de parametrização do método e os problemas que podem surgir pela utilização de pesos errados. Na literatura é frequente encontrar a atribuição de pesos idênticos a ambas as componentes. Este procedimento não permite otimizar os resultados e, principalmente, dotar o método de uma capacidade de generalização. Para reforçar esta imagem observe-se a Figura 6.28. A imagem desta figura aproxima-se mais, em termos de distribuição de intensidade, do primeiro caso de estudo, pelo que, novamente, os melhores resultados são obtidos para um aumento de  $\lambda_1$ .

Até aqui foram apresentados os resultados, e sua variação, com a alteração das componentes pesadas por  $\lambda_1$  e  $\lambda_2$ . Na função de custo existe também o parâmetro  $\mu$  que permite penalizar o comprimento da curva ou contorno. A Figura 6.29 apresenta os resultados obtidos, mantendo os restantes parâmetros fixos e iguais, quando o valor de  $\mu$  é alterado. Tal como esperado, o aumento do peso



contribui para uma redução do comprimento da curva necessário para a minimização do funcional, o que permite eliminar da imagem segmentada pequenos artefactos (reduz o número de objetos identificados) e suavizar o contorno final. Outra conclusão direta é que em imagens com características como a da Figura 6.28 e Figura 6.29 não foi possível separar completamente o corpo do feto, em virtude de este se encontrar em contacto com a parede do útero. Esta região, para um olho humano é separável. No entanto, para este método não foi possível fazer convergir o contorno para essa região por apresentar características muito idênticas ao dos tecidos do próprio feto.




Figura 6.28 – Resultado da evolução do contorno para  $\lambda_1 = 1.0$ ,  $\lambda_1 = 1.8$  e  $\lambda_1 = 2.5$  (da esquerda para a direita).  $\lambda_2 = 1.0$ . Cima: função inicial definida pelo conjunto de círculos; baixo: LS inicial resultado do GKFCM.




Figura 6.29 – Resultado da evolução do LS para  $\mu = 0.001$ ,  $\mu = 0.01$  e  $\mu = 0.02$  (da esquerda para a direita).  $\lambda_1 = \lambda_2 = 1.0$ . Cima: LS inicial definido pelo conjunto de círculos; baixo: LS inicial resultado do GKFCM.

Para além dos aspetos referidos não são visíveis, ao nível do resultado da segmentação, alterações significativas do contorno final, nomeadamente no que à região associada ao corpo do feto diz respeito. Face aos resultados observados é permitido concluir que o método Chan-Vese apresenta como principal inconveniente a necessidade de reparametrização em função da imagem alvo. Pretendendo-se um método automático, o processo deverá ser completamente autónomo e permitir adaptar cada um dos pesos em função da imagem a tratar. Neste trabalho testou-se a inclusão de um método adaptativo que permite calcular os pesos  $\lambda_1$  e  $\lambda_2$  a partir das características de intensidade da própria imagem. Neste sentido, a partir da imagem original, é analisado o histograma da distribuição de intensidades e, com base neste, calculada a relação entre o número de píxeis acima de um limiar e abaixo do mesmo. Esta relação permite identificar qual a componente que deverá possuir maior valor para melhorar a segmentação final. A Figura 6.30 contém a distribuição de intensidades para cada uma das imagens usadas nos testes.

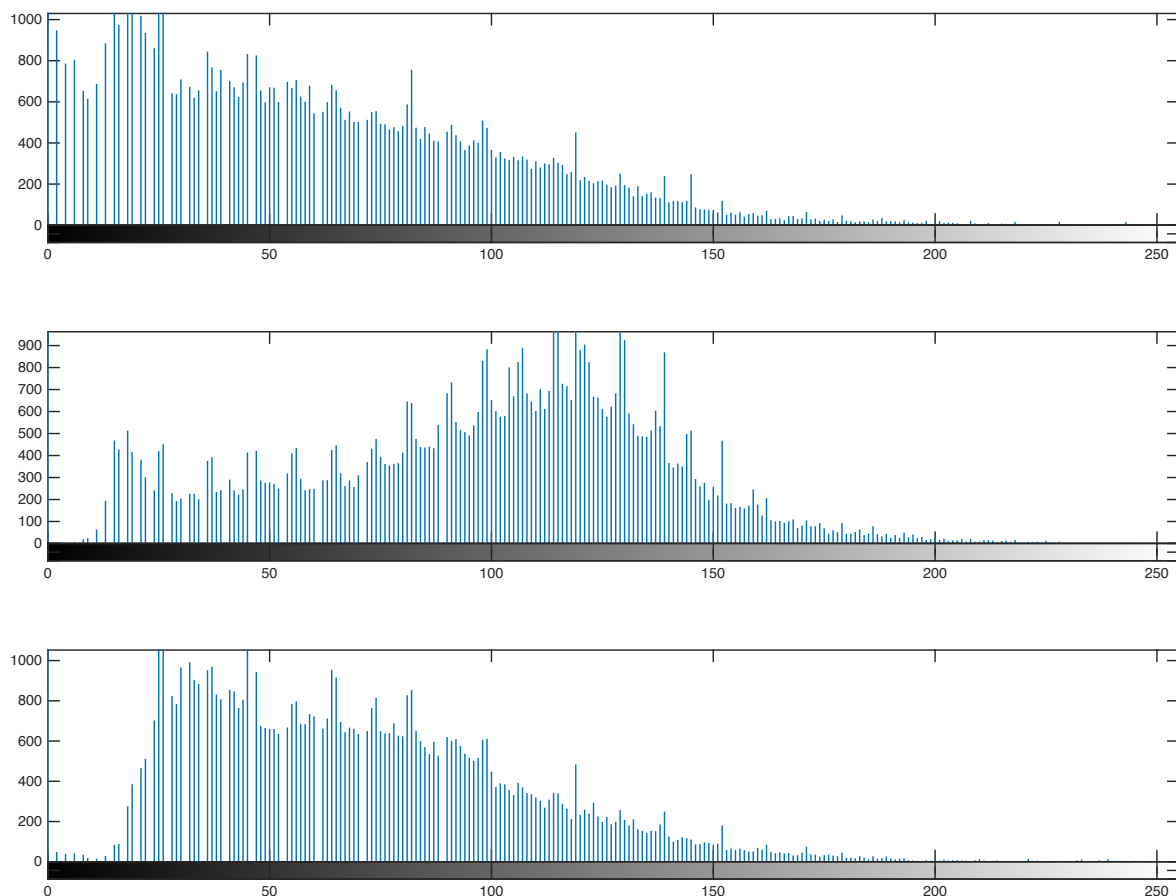


Figura 6.30 – Histograma de intensidades da Imagem 1, 2 e 3 da Figura 6.1, respetivamente.

A análise anterior revelou que as imagens com um nível médio de intensidade superior obrigam a uma aumento do peso da contribuição externa à curva, enquanto que imagens com um nível médio de intensidades mais baixas requerem que a contribuição interna se sobreponha para permitir a

convergência do contorno para uma região mais próxima da ideal. Definido o *threshold*, cada um dos pesos pode ser obtido automaticamente a partir da análise do respetivo histograma. Nos resultados que se apresentam de seguida foi usado um valor de 100 para o *threshold* por ser aquele que permite realizar uma separação entre um tipo e o outro de imagens (o tipo depende do nível médio de intensidades). A partir daqui o número total de pixéis para cada um dos intervalos é usado para calcular os pesos. Se uma imagem apresenta predominantemente intensidades mais elevadas (acima de 100) então o peso maior é atribuído à componente externa e determinado pela relação entre as duas regiões (maior/menor). Caso contrário o maior peso é atribuído à componente interna (calculada da mesma forma). Tanto num caso como no outro, o peso menor é mantido a um.

Esta estratégia foi aplicada às imagens fetais de teste tendo sido obtidos para a primeira imagem  $\lambda_1 = 4.1$ , para a segunda  $\lambda_2 = 1.5$  e para a última  $\lambda_1 = 3.8$ . O resultado para cada uma das experiências, após a execução de 5000 iterações (o número de iterações necessário à convergência aumenta com o aumento dos pesos), está representado na Figura 6.31.

Os resultados apresentados demonstram que é possível encontrar os pesos mais adequados por inspeção das características da imagem (no caso a intensidade). É importante, no entanto, salientar que os valores encontrados estão dependentes do *threshold* usado, pelo que, novamente, temos uma dependência de um outro parâmetro. Além disso, a influência dos pesos no resultado está também dependente da própria FLS usada (e.g. a alteração com o aumento do peso é menor no caso em que se utiliza o resultado GKFCM) e o tempo de convergência tende a aumentar com o aumento dos valores de  $\lambda_1$  e  $\lambda_2$ .




Figura 6.31 – Resultado da evolução do LS inicial, definido pelos círculos, após 5000 iterações, para os pesos calculados a partir do histograma da imagem. Na primeira imagem foi usado para  $\lambda_1 = 4.1$  e  $\lambda_2 = 1.0$ . Na segunda imagem foi usado para  $\lambda_1 = 1.0$  e  $\lambda_2 = 1.5$ . Na terceira imagem foi usado para  $\lambda_1 = 3.8$  e  $\lambda_2 = 1.0$ . Foi usado o mesmo valor de  $\mu$  em todas as simulações.

Os testes realizados permitiram caracterizar o desempenho do método Chen-Vese na segmentação das imagens fetais perante parametrização diversa. Os resultados observados demonstram que existe uma grande dependência dos valores dos parâmetros usados e que estes necessitam ser reajustados em função da imagem a segmentar. Este conjunto de circunstâncias dificulta a utilização do método em

casos semelhantes ao estudo particular deste trabalho, pelo que métodos alternativos ou complementares terão de ser encontrados por forma a reduzir a dependência dos resultados da parametrização e do tipo de imagem de entrada.

## 6.5 Segmentação de Imagens Fetais com Recurso a um Classificador SVM

Tal como referido no capítulo 5, as SVMs são caracterizadas por possuírem uma capacidade de generalização elevada que lhe é fornecida pelo facto de minimizarem o risco estrutural em detrimento do risco empírico. Os métodos testados até ao momento (FC e Contornos Ativos) apresentam como maior inconveniente a sua dependência de parametrizações que, em termos gerais, comprometem a generalização e, como tal, o resultado da segmentação perante imagens com características variáveis. Assim sendo, a utilização do classificador SVM no contexto deste trabalho representa um importante contributo para a segmentação das imagens fetais com vista à obtenção da DCC.

O classificador foi implementado recorrendo a duas abordagens distintas. Numa primeira abordagem usaram-se apenas os pontos referentes ao contorno como elementos de treino do classificador, enquanto que na segunda, para além destes, foram também usados os pontos internos e que constituem o corpo do feto. Desta forma pretendeu-se avaliar a importância da informação do corpo fetal no processo de decisão da SVM e analisar se essa informação é útil para melhorar o desempenho do classificador.

### 6.5.1 Segmentação Baseada no Contorno Fetal

De entre um conjunto de 20 imagens obtidas por um obstetra, Dr. Matos Cruz, para a realização da medida da DCC foram seleccionadas 15. Nestas últimas foram assinalados, manualmente, os pontos do contorno do feto e etiquetados como casos positivos para o treino. De entre os restantes pontos foram seleccionados, alternadamente e em igual número, pixels que foram classificados como os casos negativos para o treino. Para cada ponto de treino, casos positivos e negativos, foi extraído da imagem um vetor de 842 características de acordo com o procedimento indicado na subsecção 5.8 e que consistiu em estabelecer uma máscara de extração radial, com raio 60, definida para 24 raios distintos, distribuídos linearmente (em termos angulares) pela região da máscara. Para cada raio foram retirados, alternadamente para cada pixel nessa direcção, o valor de intensidade do próprio pixel e a diferença relativamente ao pixel central. Deste processo resultou um conjunto de 842 características primárias, que foi submetido a uma PCA e que permitiu reduzir o espaço de características inicial para

30 componentes principais. As componentes principais identificadas foram usadas como elementos de treino da SVM e constituem o espaço de características de entrada. O resultado do treino foi uma SVM caracterizada por cerca de 9000 vetores de suporte em aproximadamente 170 000 padrões de treino (aquisições realizadas pela máscara ao longo das imagens com saltos de 4 em 4 píxeis). O modelo de classificação obtido foi posteriormente aplicado a imagens usadas no treino (Figura 6.32) e a imagens nunca vistas pelo classificador, designadas por imagens de teste (Figura 6.33).




Figura 6.32 – Resultados da segmentação para algumas das imagens de treino. A imagem da esquerda corresponde à imagem original, a imagem central à anotação realizada manualmente e a da direita ao resultado da aplicação da SVM.

Os resultados apresentados referem-se aos melhores resultados obtidos face aos testes efetuados com parametrizações da distância radial da máscara e do peso associado ao erro de classificação da SVM,  $C$ , indicado na subsecção 5.5.3 e cujo valor usado foi  $C = 15$ . Os resultados obtidos apontam para um bom desempenho do classificador, mesmo considerando os resultados nas imagens de teste e que



nunca foram usadas no treino. Relativamente às imagens de treino, a SVM foi capaz de extrair corretamente os pontos do contorno, apresentando um baixo índice de falsos positivos, o que mesmo para as imagens de treino representa um bom indicador relativamente à especificidade e sensibilidade do classificador. Analisando o comportamento do classificador perante as imagens de teste, Figura 6.33, pode-se concluir que, de uma forma geral, os resultados confirmam a possibilidade do uso com sucesso deste tipo de abordagem na segmentação das imagens fetais. Note-se que a grande maioria dos pontos assinalados como pertencentes ao contorno destas imagens encontram-se efetivamente sobre este.




Figura 6.33 – Resultados da segmentação para imagens não treinadas. À esquerda a imagem original e à direita o resultado do classificador.

Estes resultados são bem mais animadores se atendermos ao facto de apenas **15** imagens terem sido usadas no treino do classificador, o que representa um universo manifestamente reduzido face às possibilidades reais. Apesar disso, para as imagens com características próximas das imagens de

treino (as 3 primeiras imagens da Figura 6.33) a segmentação final aproxima-se bastante dos resultados desejados, sendo evidente a forma fetal nos pontos obtidos. A última imagem de teste apresentada, e aquela onde foram obtidos os piores resultados, foi obtida através de digitalização com recurso a um *scanner* ótico a partir de uma impressão em papel e apresenta uma relação sinal/ruído inferior ao normal, especialmente nas regiões de *background*. São evidentes as diferenças no preto de fundo desta imagem relativamente às restantes apresentadas. Apesar disso, a maioria dos pontos assinalados coincidem efetivamente com o contorno fetal.

Neste contexto, o desempenho do classificador poderá ser melhorado significativamente através do aumento do número de imagens de treino, especialmente se estas cobrirem um leque alargado de possíveis cenários. De entre estes, destacam-se a existência de imagens com posições fetais variadas e com contraste e brilho diverso. Note-se que a máscara radial híbrida usada na extração das características não é invariante à rotação, pelo que este aspeto poderá ser compensado pela existência de imagens com o feto em posições variadas.

#### 6.5.2 Segmentação Baseada no Contorno e Corpo Fetal

A utilização de uma máscara que permitisse retirar informação mais abrangente sobre o corpo completo do feto poderia melhorar a qualidade da segmentação. À escala normal das imagens usadas, 310x220 pixels, esta abordagem obrigaria a um aumento significativo do raio usado e, consequentemente, a um aumento do número de características. Uma forma de resolver este problema consiste em alterar a escala da imagem original por forma a que, para a mesma dimensão da máscara radial híbrida, se possam obter os resultados esperados. Por este motivo procedeu-se a uma redução de escala de 40% das imagens originais e aplicou-se novamente o extrator de características já referido que, depois de filtradas pela PCA, foram usadas no treino da SVM. Todos os pontos no interior do contorno anotado foram considerados como casos positivos de classificação e, de entre os restantes pixels, selecionados novamente exemplos negativos em igual número aos casos positivos. A utilização desta informação mais abrangente pretende dotar o classificador de habilidade para identificar por completo o corpo do feto e não apenas os seus contornos e desta forma encontrar mecanismos que lhe permitam classificar corretamente regiões em falta, afetadas por ruído ou em falha de representação.

O classificador obtido por este processo foi aplicado novamente às imagens usadas no treino e às imagens de teste e estão representados, respetivamente, na Figura 6.34 e Figura 6.35.

À semelhança do método descrito na subsecção anterior os resultados da segmentação para as imagens de treino são muito satisfatórios. O classificador denotou uma elevada capacidade para reconhecer apenas pontos do corpo do feto, apresentando um índice de falsos positivos baixo, tal como pode ser constatado nas imagens apresentadas na Figura 6.34.




Figura 6.34 – Resultado da classificação da SVM sobre algumas das imagens de treino depois de treinada com as características extraídas da imagem reescalada para 40% do tamanho original com máscara de 24 raios,  $C=15$  e usadas 25 componentes principais. À esquerda a imagem original, ao centro as imagens anotadas e à direita o resultado da segmentação.

Para as imagens de teste, apesar de a segmentação não ser ótima, o classificador volta a apresentar uma elevada capacidade para reconhecer apenas elementos do corpo fetal o que, face ao número reduzido de imagens usadas no treino, é um bom indicador da capacidade de generalização da máquina de aprendizagem usada.

Estes resultados, bem como os indicados na subsecção 6.5.1, apontam para a possibilidade de realizar com sucesso a segmentação das imagens fetais relativas à medição da DCC. Comparativamente aos métodos de FC e Contornos Ativos sugeridos, a SVM permite rejeitar os tecidos das regiões de junção entre o feto e a cavidade uterina e melhorar o resultado da segmentação nas regiões de interesse.




Figura 6.35 - Resultado da classificação da SVM sobre algumas das imagens de teste depois de treinada com as características extraídas da imagem reescalada para 40% do tamanho original, máscara de 24 raios,  $C=15$  e usadas 25 componentes principais.

### 6.5.3 Desempenho do Classificador em Função do Número de Componentes Principais, da Máscara e do Peso do Erro de Classificação da SVM

Para se avaliar a influência do número de componentes principais usadas no treino da SVM, a influência do valor do erro de classificação da SVM usado na fase de treino (constante  $C$  definida na subsecção 5.5.3) e a influência do número de raios da máscara radial usada na extração das características primárias foi realizado um conjunto de testes em que se permitiu a variação independente de cada um destes parâmetros. Genericamente, os resultados obtidos, representados na Figura 6.36, Figura 6.37 e Figura 6.38, sugerem que a diminuição do número de componentes principais usadas no treino do classificador, a diminuição da constante  $C$  e o aumento do número de raios usados pela máscara de extração contribuem para uma melhoria da capacidade de generalização. No entanto, a classificação sobre os dados de treino é piorada.

O efeito da redução do número de componentes principais usadas pelo classificador é interessante, pois indica a existência de informação redundante que pode contribuir para a menor separabilidade dos dados e, conseqüentemente, para maiores dificuldades de classificação. Note-se, no entanto, que para valores inferiores a 20 componentes principais o classificador apresentou um desempenho inferior, o que é um indicador de que as características dadas pelo PCA possuem informação ainda útil até a vigésima componente. Por outro lado, a introdução de muitas mais componentes promove a redução da capacidade de generalização e conseqüente *overfitting*.




Figura 6.36 – Resultado da segmentação com  $C=15$ , 25 componentes principais (imagem central) e 20 componentes principais (imagem à direita) para uma imagem de treino (cima) e uma imagem de teste (baixo) e máscara de 24 raios.




Figura 6.37 - Resultado da segmentação com  $C=15$  (imagem central),  $C=5$  (imagem à direita), 20 componentes principais para uma imagem de treino (cima) e uma imagem de teste (baixo) e máscara de 24 raios.

O aumento do número de raios contribui para o aumento do número de características associadas aos padrões de treino, pelo que aumenta a carga computacional exigida na fase de treino e, naturalmente, na fase de execução.




Figura 6.38 - Resultado da segmentação com  $C=5$ , 20 componentes principais, máscara de 24 raios (imagem central) e 36 raios (imagem à direita) para uma imagem de treino (cima) e uma imagem de teste (baixo).

É importante referir que o aumento da capacidade de generalização com a variação dos parâmetros referidos foi a tendência observada para a maioria das imagens de teste usadas. Existem, no entanto, imagens para as quais o classificador apresentou resultados idênticos ou até piores, pelo que conclusões mais generalistas acerca do comportamento do classificador face à variação dos parâmetros indicados exigem um conjunto de testes mais alargado.

Como conclusão refira-se que existe uma possibilidade muito vasta para o domínio de entrada do classificador e que afeta a capacidade de generalização. As imagens resultantes dos equipamentos de aquisição apresentam variações de equipamento para equipamento que se manifestam em diferenças nos tons usados na representação dos tecidos, diferenças no contraste das imagens adquiridas, diferenças na representação do *background* e diferenças ao nível da representação do ruído introduzido. A estes fatores acrescem a variação posicional do feto de imagem para imagem, a possibilidade de este se encontrar em contacto com as paredes do útero (pelo que o tecido fetal se pode confundir com o tecido da cavidade uterina), as variações, ainda que mínimas, de escala da imagem usada e as diferenças morfológicas do próprio feto e bolsa uterina. Neste contexto, um classificador deste género tenderá a melhorar o seu desempenho se possuir informação relevante que permita cobrir todos os aspetos referidos e que poderá ser alcançado através da formação de uma base de treino com exemplos representativos da diversidade possível. Ressalve-se, no entanto, que, apesar de tudo isto e apesar de a base de treino ser reduzida, a SVM apresentou uma especificidade elevada para classificar apenas pontos do contorno ou do corpo fetal, mesmo nos casos em que o nível de segmentação foi reduzido, o que é um indicador importante da possibilidade de atingir bons resultados com o aumento dos exemplos. Por outro lado é bem conhecido o problema de escalabilidade que as SVMs apresentam (Burgess, 1998) e que aqui são previstos/tratados pela utilização do método PCA.

## 6.6 Extração da Distância Crânio-Caudal

A obtenção da DCC foi realizada segundo 4 abordagens distintas. As 3 primeiras consistiram em extrair a informação relativa aos pontos de medição a partir das imagens segmentadas, resultado da aplicação da SVM descrita na secção anterior. A outra consistiu em implementar uma nova SVM treinada para identificar os dois pontos específicos da medida. As subsecções seguintes incluem a descrição da implementação de cada um dos métodos e os resultados obtidos.

### 6.6.1 Extração a Partir das Imagens Segmentadas – Método 1

A forma mais simples de encontrar os dois pontos da medição a partir das imagens segmentadas é através da consideração dos pontos extremos do corpo do feto segmentado ao longo do eixo horizontal. A Figura 6.39 apresenta os resultados para este tipo de abordagem. As 3 primeiras imagens, para além do resultado obtido (cruz vermelha) contêm a anotação do obstetra.






Figura 6.39 – Marcação dos pontos de medida usando a aproximação dos pontos extremos resultantes da segmentação. O resultado do detetor está assinalado com uma cruz vermelha e a verde a marcação manual tida como correta.

A utilização desta metodologia exige uma segmentação ideal ou muito próxima dela. Nestes casos os pontos obtidos estarão relativamente próximos dos pontos “reais”. Nos restantes casos poderão ocorrer marcações incorretas resultantes do reconhecimento de tecidos periféricos como tecidos do corpo fetal. Por outro lado, o resultado será tão mais próximo do “valor correto” quanto a imagem mais se aproximar do *standard* definido para a aquisição de imagens com vista à medição da DCC (caso da imagem superior direita).

#### 6.6.2 Extração a Partir das Imagens Segmentadas – Método 2

Outra alternativa implementada consistiu em extrair das imagens segmentadas informação relativa à possível orientação da cabeça e tronco fetais. A partir da imagem inicial foram retiradas duas subimagens, uma que contém a parte esquerda e a outra que contém o lado direito (Figura 6.41). A partir destas, foi realizada a deteção da orientação do feto (se a cabeça está à esquerda ou à direita). No caso em que a cabeça está à direita, genericamente, a diferença entre o extremo superior e o extremo inferior da imagem direita é maior que a da esquerda. Esta informação melhora a qualidade de deteção da medida pois permite criar estratégias distintas em função da posição do feto.

Os pontos extremos, para além de serem usados para detetar a posição fetal, são usados para encontrar um ponto da cabeça e um ponto da região caudal (Figura 6.42). A partir destes, é traçado um círculo com uma distância próxima do ponto extremo no eixo horizontal da imagem, mas que permita a interseção do contorno do feto. No caso em que não exista interseção do círculo com o contorno do feto o raio é diminuído até que essa interseção seja possível de encontrar (Figura 6.43).



Para a detecção do ponto de medida da subimagem esquerda é testada a interseção do círculo para um ângulo entre  $180^\circ$  e  $245^\circ$  e considerado como ponto de medida o último ponto comum entre o círculo e o contorno. No caso da subimagem da direita é testada a interseção para ângulos entre  $0^\circ$  e  $65^\circ$  e considerado o último ponto de cruzamento entre o círculo de detecção e o contorno. Nos casos em que a cabeça está à esquerda a variação dos ângulos de detecção são alterados. Nestes casos, para a cabeça é usada uma variação desde os  $125^\circ$  aos  $180^\circ$  e usado o primeiro ponto de interseção e para o tronco dos  $0^\circ$  aos  $-65^\circ$  e usado o último ponto de interseção. O ponto definido pelos extremos de cada subimagem estabelece uma indicação da orientação da cabeça e da região da nádega e permite realizar a aproximação a um círculo, cujo ponto de interseção (segundo a metodologia indicada) se aproxima do ponto mais correto de medição.




Figura 6.40 – Imagem original e resultado da segmentação por aplicação da SVM.



Figura 6.41 – Subimagem esquerda e direita.




Figura 6.42 – Pontos extremos detetados e o ponto central para desenho do círculo obtido a partir destes.




Figura 6.43 – Marcação dos círculos para determinação dos pontos de medida. Para a imagem esquerda é selecionado o último ponto de contacto do círculo com o contorno visto no sentido descendente. Para a imagem à direita o último ponto de contacto do círculo com o contorno no sentido ascendente. O método é alterado em função da orientação do feto.

Os resultados obtidos para algumas imagens são apresentados na Figura 6.44.



Figura 6.44 – Resultados da marcação dos pontos de medição da DCC com o algoritmo descrito. A vermelho o resultado da marcação manual e a amarelo os pontos detetados pelo algoritmo.

### 6.6.3 Extração a Partir das Imagens Segmentadas – Método 3

Outra abordagem testada consistiu na utilização da medida da orientação da imagem global e das subimagens parciais esquerda e direita. A orientação é definida pelo ângulo entre o eixo horizontal da imagem e o eixo principal da elipse que possui o mesmo momento de inércia que a região da imagem. Além do ângulo que define a orientação das subimagens parciais e da imagem global foi determinado o centroide de cada subimagem e, a partir deste, traçada uma reta com uma inclinação angular determinada pela média da orientação obtida para a imagem global e para a subimagem parcial em causa. O ponto de interseção da reta com o contorno indica o ponto de medida (Figura 6.45).

Este mecanismo revelou ser menos robusto e os resultados obtidos de menor qualidade comparativamente aos do método anterior (Figura 6.46). Contudo, para imagens semelhantes à terceira imagem apresentada na Figura 6.46, o resultado da medição aproxima-se mais ao resultado obtido pela marcação do operador humano. Isto deve-se ao facto de a orientação angular da imagem global ser aproximadamente nula, pelo que a linha de marcação depende essencialmente da orientação da subimagem, a qual nestes casos acaba por se aproximar dos pontos corretos de

medição. Refira-se que este tipo de imagens é o indicado e sugerido aos especialistas para a realização da medida DCC.




Figura 6.45 – Marcação do centroide de cada subimagem e a reta com inclinação definida pela orientação da imagem global e da orientação de cada subimagem. O ponto de interseção da reta com o contorno define o ponto de medida.



Figura 6.46 – Resultados da marcação dos pontos de medida com recurso à utilização do centroide de cada subimagem e da orientação da imagem global e orientação da imagem parcial. A amarelo a marcação automática e a vermelho a marcação manual.

#### 6.6.4 Avaliação dos Resultados das Medições

A Tabela 6.5 apresenta o resultado do erro absoluto médio, visto relativamente à distância manual, para cada um dos métodos descritos considerando os resultados sobre as imagens corretamente segmentadas. O valor do erro é visto como a diferença, em valor absoluto, entre a medida manual e a medida automática.

Tabela 6.5 – Erro absoluto médio, em percentagem, da medição para cada um dos métodos apresentados considerando apenas as marcações sobre as imagens corretamente segmentadas.

	Método 1	Método 2	Método 3
<b>Erro Médio (%)</b>	2,5	1,0	2,6

É importante referir que o erro apresentado diz respeito a medições realizadas sobre imagens cuja segmentação foi realizada com sucesso. De uma forma geral, qualquer um dos métodos usados apresenta um erro relativo baixo e que tende a diminuir para imagens que cumpram com as normas

sugeridas para a aquisição com vista à medição da DCC, como é o caso da segunda e terceira imagem da Figura 6.46.

Os valores do erro observados enquadram-se nos intervalos de variação indicados por outros autores. Não é, no entanto, possível estabelecer uma comparação mais assertiva na medida em que não tivemos, no decorrer, deste trabalho acesso às imagens usadas nesses trabalhos. Atendendo a que o valor do erro depende do tipo de imagem um estudo comparativo exigiria o uso das mesmas imagens. Outro aspeto importante refere-se à comparação do erro absoluto médio observado face à variação inter-operador. Alguns estudos apontam para variações das medidas entre operadores entre os 1,6% e os 3,7%, dependendo da medida realizada (Carneiro *et al.*, 2008; Chalana *et al.*, 1996), pelo que as medidas extraídas por qualquer um dos métodos apresentam um erro médio dentro deste intervalo.

#### 6.6.5 Extração da Medida DCC com Recurso a Classificador SVM

A partir de imagens anotadas manualmente foi treinada uma nova SVM. O objetivo era dotá-la de mecanismos que lhe permitam identificar os dois pontos em causa e necessários à realização da medida. A partir das regiões anotadas (correspondentes às regiões usadas para a medição) foram retiradas as características de treino seguindo o mesmo mecanismo descrito na secção 5.8. O conjunto obtido foi submetido a PCA para redução do espaço de características resultando num conjunto de 16 componentes principais que foram usadas para treinar o classificador. No treino da SVM foi usado um erro de classificação  $C = 15$ .

A Figura 6.47 e Figura 6.48 apresentam os resultados do classificador para as imagens usadas no treino e as imagens de teste, respetivamente.






Figura 6.47 – Resultados da marcação dos pontos de medição da SVM para algumas das imagens de treino. À esquerda a imagem original com a marcação do obstetra, ao centro as marcações para o treino e à direita, assinalado a branco e envolvido pelo círculo os pontos classificados como pertencentes à região de medição pela SVM.

Atendendo ao facto de que o treino foi realizado recorrendo apenas a 15 imagens, os resultados vão no sentido daquilo que já foi referido anteriormente, isto é, a SVM aparenta possuir capacidade para realizar com sucesso a tarefa de obtenção dos pontos de medição.

Todas as imagens usadas no treino foram corretamente assinaladas pela SVM. Nas imagens de teste apenas cerca de 50% das imagens usadas foram corretamente identificadas. Considera-se corretamente identificada a imagem cujo classificador assinalou pontos coincidentes com ambos os pontos de medida assinalados pelo operador humano. Por exemplo, a imagem inferior direita da Figura 6.48, não é considerada como corretamente identificada.

Os aspetos referidos relativamente à segmentação com recurso à SVM são válidos para este caso também. Face à diversidade possível de imagens, a amostra usada no treino é insuficiente para garantir um bom desempenho da SVM em fase de execução. É, no entanto, interessante observar que o classificador voltou a apresentar bons resultados nas imagens com características globais próximas das usadas no treino (caso de 3 das 4 imagens apresentadas na Figura 6.48).




Figura 6.48 – Resultado do classificador para quatro imagens de teste. À esquerda duas imagens onde a classificação foi bem sucedida e à direita mal sucedida.

## 6.7 Conclusão

Neste capítulo foram apresentados os resultados da aplicação das estratégias discutidas nos capítulos 3, 4 e 5 na segmentação das imagens fetais com vista à determinação da DCC. Numa primeira abordagem recorreu-se à utilização de metodologias de FC, segundo diversas variantes, que introduzem ao método FCM habitual a possibilidade de incluir na função de custo informação espacial. Esta vertente melhora o desempenho do classificador reduzindo os efeitos do ruído existente neste tipo de imagens. Destes, o GKFCM apresentou, genericamente, os melhores resultados para o conjunto de imagens usados. O método substitui a medida da distância euclidiana tipicamente usada por uma medida não linear do tipo gaussiano e permite pesar a influência da vizinhança em cada *cluster* de forma individual. Estes aspetos contribuem para a melhoria do classificador, principalmente na presença de ruído.

A solução seguinte passou por apresentar um método de contornos ativos baseado em análise funcional, implementado com recurso a LS e que não usa no processo de evolução do contorno informação de gradiente (método Chan-Vese). Em imagens com elevado nível de ruído, a evolução do contorno pode ficar comprometida com a utilização do gradiente, pelo que a escolha deste método parece a mais indicada para resolver o problema proposto. Os resultados obtidos apontam para a possibilidade de realizar com sucesso relativo a segmentação. Existe, no entanto, um inconveniente: possui baixa capacidade de generalização, obrigando a uma reparametrização em função do tipo de imagem usada. Este mesmo problema é observado nos métodos de FC com informação espacial, o que compromete a capacidade de generalização e, evidentemente, o desempenho funcional para variações das imagens de entrada.

Tanto no caso dos métodos de FC como no caso do método de contornos ativos usados existe uma evidente falta de informação relativa à forma do objeto a identificar. Essa informação é, especialmente relevante nos casos em que existe a junção do feto à parede uterina. Como forma de colmatar esta insuficiência e melhorar o resultado da segmentação, foi implementada a Transformada de Hough Generalizada (THG) (Ballard, 1981). Estabelecida a forma de referência (correspondente a uma forma do feto mais comum) a THG foi aplicada ao resultado das segmentações realizadas por ambos os métodos. Os resultados mostraram um sucesso muito relativo na aplicação desta estratégia e daí não terem sido apresentados resultados da sua aplicação. Na maior parte dos casos a identificação foi mal realizada ou por ser feita a uma escala incorreta ou por reconhecer a forma numa região da imagem errada.

Por último, no que à segmentação diz respeito, foi apresentado um modelo baseado em estratégias de aprendizagem automática: SVMs. A SVM foi treinada com características extraídas de 15 imagens fetais com recurso a uma máscara híbrida radial filtradas através de PCA *whitening*, que permitiu projetar o conjunto de características inicial num subespaço de menor dimensão e, como tal, computacionalmente menos dispendioso e potenciador de generalização. Os resultados obtidos indicam que é possível realizar com sucesso a segmentação recorrendo a esta estratégia. Estes podem ainda ser melhorados através da inclusão de mais exemplos de treino que possibilitem abranger um conjunto mais alargado de imagens e, consequentemente, melhorar a capacidade de generalização. É importante referir que as imagens usadas foram obtidas com recurso a equipamentos de fabricantes diferentes, pelo que apresentam características distintas que dificultam a generalização. Apesar disso, o classificador realizou com sucesso a segmentação de imagens próximas das imagens de treino e, nos restantes casos apresentou uma boa especificidade e sensibilidade. Por outro lado, a utilização no treino da informação do corpo fetal, em alternativa ao contorno fetal, permitiu avaliar a influência destas características na capacidade generalizadora do modelo proposto. Os resultados permitem observar ligeiras melhorias no resultado da segmentação. No entanto, o número reduzido de imagens de teste não permite realizar uma avaliação estatisticamente representativa.

Foi também observado o desempenho da SVM face à variação do erro de classificação associado ( $C$ ), do número de componentes principais usadas e do número de raios da máscara radial híbrida. Confirmou-se, no âmbito das imagens fetais, que a diminuição do valor de  $C$  contribui para aumentar a margem associada ao classificador, pelo que a distância entre os hiperplanos definidos pelos vetores de suporte que delimitam cada uma das classes é maior e, por consequência, aumentamos a capacidade de generalização, ainda que o erro empírico aumente. Efetivamente, como consequência deste facto observou-se um resultado na segmentação das imagens de teste superior quando  $C$  adquiria valores mais baixos. A observação da alteração do comportamento do classificador face ao número de componentes principais usado é importante pois reflete a capacidade do método em seleccionar as características mais significativas para a melhor diferenciação das classes de segmentação. Um número de componentes abaixo do ideal produziu *underfitting* enquanto que um número de componentes acima do ideal produziu *overfitting*. Face à dimensão do espaço de características primárias resultantes da aplicação da máscara radial híbrida a redução da dimensionalidade do problema é fundamental pois permite também reduzir os custos computacionais sem comprometer o desempenho funcional, ao mesmo tempo que minimiza a complexidade do espaço de entrada o que potencia a minimização da "praga da dimensionalidade". A PCA, como

verificado, tem a virtude de eliminar características redundantes e, como tal, melhorar a separabilidade dos dados melhorando também a capacidade generalizadora em colaboração com a própria SVM. Esta característica é ainda sensivelmente amplificada pela utilização do processo de *whitening*. Além disso, a PCA permite a utilização de máscaras de extração de maior dimensão. O aumento da distância de ação da máscara implica o aumento do número de características primárias. No entanto, isto não implica de forma direta o aumento proporcional do número de características de treino. Estas são selecionadas pela PCA. É importante que a máscara de aquisição seja relativamente ampla para abranger um domínio mais global da região do feto promovendo a observação, para posterior correta classificação, de características distantes e fundamentais na perceção da região e sub-regiões do feto. Porém, o aumento do espaço de hipóteses trazido pelo aumento da máscara, dada a natureza das imagens, tem que ser compensado pelo incremento da variedade de situações na constituição dos padrões de treino.

Por último, o aumento do número de raios permitiu aumentar também a capacidade generalizadora do sistema classificador. Note-se que este aumento implica, à semelhança do aumento do raio de ação, um aumento do número de características primárias. A observação da melhoria do comportamento do classificador face ao aumento do número de raios usados, mantendo o número de componentes principais, permite concluir que a informação direcional é importante para o classificador. Este aspecto estará também relacionado com a própria natureza das imagens em correlação com o extrator usado o que permite realizar uma caracterização geométrica da região (curvatura).

Com vista à obtenção da DCC foram implementadas e testadas 4 metodologias distintas. Três delas recorrem à imagem segmentada e a outra recorre a uma SVM treinada para identificar os pontos específicos da medida, sendo que estes pontos são depois cruzados com o resultado da segmentação como forma de aumentar a robustez do classificador. De entre as abordagens que recorrem ao resultado do segmentador proposto, aquelas que usam a informação da orientação das regiões associadas ao crânio e à cauda apresentam melhores resultados. Isto significa que existe uma relação direta entre a orientação de cada sub-região e o próprio ponto de medição. Refira-se que os mecanismos de extração da medida da DCC encontrados na literatura recorrem apenas aos pontos extremos da região definida pelo corpo do feto, pressupondo que estes limites coincidem com os pontos de interesse. Os resultados observados mostram que os modelos de obtenção da medida DCC baseados na medida da orientação da imagem, e por nós propostos, apresentam melhores resultados, nomeadamente quando comparados com a variabilidade intra-operador.



## CONCLUSÕES GERAIS E TRABALHO FUTURO

O objetivo proposto no início deste trabalho consistiu na análise/elaboração de métodos e abordagens que permitissem realizar a segmentação das imagens fetais e extrair a medida DCC.

O problema a tratar não é simples. Os sistemas de aquisição de imagem por ultrassons possuem um conjunto de limitações que se refletem em imagens com baixo detalhe, baixo contraste e com artefactos, associados essencialmente ao problema de propagação do sinal, e que dificultam a tarefa de reconhecimento dos objetos na imagem. A extensa revisão do estado da arte referida no capítulo 2 é comprovativo disso mesmo. Apesar da grande diversidade de estratégias usadas, muitas delas até recorrendo à associação de métodos, os resultados apresentados pelos autores indicam limitações nos algoritmos implementados, mesmo nos casos em que tratam as tarefas mais simples, como sejam a medição do DBP ou do comprimento do fémur.

Para a execução deste trabalho foram selecionadas três abordagens distintas que, pela sua natureza, apresentavam características adequadas à sua utilização na resolução do problema proposto e que, de acordo com a literatura consultada, nunca foram usadas para esse fim.

Numa primeira abordagem foi feita uma análise exploratória ao desempenho dos principais métodos de FC e Contornos Ativos na segmentação das imagens fetais. Relativamente aos primeiros testou-se e analisou-se o comportamento do método clássico FCM e variantes deste que permitem otimizar a partição final de acordo com a informação espacial local. A inclusão desta componente permitiu reduzir os efeitos do ruído no *clustering*, contribuindo para as melhorias observadas nos classificadores que a usam. Apesar disso, as estratégias usadas não permitem tratar casos de imagens com regiões relevantes representadas com características semelhantes ao próprio *background* que, frequentemente, são usadas pelos especialistas.

A metodologia de contornos ativos analisada tem a particularidade de não usar a informação habitual do gradiente para realizar a aproximação ao contorno dos objetos e que, em nosso entender, é adequada ao tipo de imagens em estudo. Os resultados observados mostram um bom desempenho do algoritmo para encontrar as regiões do contorno. No entanto, nos casos em que o corpo fetal se encontra em contacto com a parede do útero não foi possível realizar com sucesso total a segmentação. Esta limitação, inerente à estrutura de implementação do próprio método, está relacionada com o facto de a representação dos tecidos nas imagens não apresentarem diferenças significativas de textura. Sendo a aproximação da curva ao contorno realizada pela minimização do

funcional que mede a energia associada à componente interna e externa ao próprio contorno, as regiões com texturas semelhantes serão incluídas no mesmo grupo.

Estas abordagens, para além das limitações já evidenciadas, apresentam também baixa capacidade de generalização, necessitando reparametrização variável em função das imagens de entrada. Este aspeto é mais evidente no método de contornos ativos onde o resultado da segmentação é mais influenciado pelos pesos atribuídos às componentes interna e externa à curva de adaptação.

Os resultados obtidos por ambas as implementações denotam uma evidente falta de informação relativamente ao objeto a identificar: a forma. Esta informação existe no cérebro humano e é um fator importante para o nosso sucesso na segmentação. No seguimento desta constatação, sobre o resultado das segmentações pelas abordagens descritas, implementou-se um detetor de forma baseado na THG. Os resultados obtidos mostraram uma incapacidade do detetor em encontrar a forma de referência estabelecida (correspondente à forma do corpo fetal), identificando o feto ora a escalas erradas, ora em regiões erradas, sendo que a taxa de sucesso foi muito reduzida. Esta foi a principal razão pela qual não foram apresentados resultados da aplicação da metodologia.

A terceira solução apresentada, e que corresponde à maior contribuição deste trabalho, recorreu a técnicas de ML para segmentar a imagem: SVMs. As SVMs são reconhecidas por serem bons classificadores. Esta capacidade advém de, na fase de treino, recorrer à minimização do risco estrutural em substituição do habitualmente usado risco empírico e que lhe fornece um carácter generalizador e um melhor desempenho funcional na fase de execução quando comparadas com outras abordagens de ML (e.g. redes neuronais artificiais). Esta característica é importante num classificador e mais importante ainda no contexto deste trabalho face à variabilidade de imagens possíveis de encontrar. O classificador foi treinado a partir de um conjunto de características de treino extraído através de uma máscara radial híbrida filtrada através de PCA com *whitening*. A máscara usada permitiu criar um conjunto de características que conjuga a informação do pixel central da máscara com a informação dos pixels na sua vizinhança na forma direta e de variação. Esta última pode ser importante pois melhora o comportamento do classificador perante as variações de brilho de imagem para imagem. A informação direta dos pixels vizinhos, segundo a direção de cada raio, ajuda a eliminar as possíveis influências do ruído, integrando características direcionais importantes. Outro aspeto importante da máscara radial híbrida usada refere-se à sua abrangência. Os testes efetuados permitiram definir uma máscara com dimensão de 60 pixels cuja abrangência é fundamental para caracterizar de forma mais global as regiões do feto (e.g. curvatura da cabeça).

A utilização do método PCA *whitening* permitiu reduzir o espaço de características primárias a um subespaço de menor dimensão e que, para além de reduzir o esforço computacional, melhora a separabilidade dos dados e, consequentemente, a generalização. O número de componentes principais usadas para o espaço de características de treino/classificação foi determinado por testes para diferentes valores e avaliação do erro associado (observação do resultado sobre as imagens de teste). Foram testadas duas SVMs na deteção do corpo fetal. A primeira foi treinada com pontos do contorno fetal definido pelo operador humano e pontos não pertencentes ao contorno e a segunda com pontos do corpo fetal, casos positivos, e pontos restantes, casos negativos. A inclusão da informação do corpo fetal pretendia no fundo estabelecer para o treino algum indicador de forma, permitindo observar se as características do corpo fetal poderiam ter um caráter mais generalizador que as características do contorno fetal.

Os resultados observados são indicadores da possibilidade de realizar com sucesso a segmentação da imagem com recurso a estas estratégias. Ambos os classificadores apresentaram ótimos resultados sobre o conjunto de treino e aceitáveis sobre o conjunto de testes, tendo apresentado boa sensibilidade e especificidade em ambos os casos. Estes indicadores tomam um significado maior se relacionados com o número de imagens usadas no treino e com a variabilidade possível das imagens fetais. A utilização de um número superior de imagens para o treino iria permitir reduzir o erro do classificador na fase de execução. Por outro lado, a utilização da informação do corpo fetal usada no treino da segunda SVM permitiu introduzir algumas melhorias na qualidade da segmentação. Uma conclusão estatisticamente mais conclusiva sobre a influência do corpo fetal na classificação exige, no entanto, um conjunto mais alargado de imagens de teste.

Para a medição da DCC foram apresentadas diversas estratégias. Uma delas recorreu à implementação de uma SVM, treinada para reconhecer os pontos específicos das regiões de medida. Os resultados apontam para a possibilidade de identificar os pontos de medição com recurso a esta estratégia e para que as limitações maiores decorram da falta de imagens de treino.

As restantes metodologias usadas usam o resultado da segmentação para determinar a medida. As estratégias que apresentam melhores resultados baseiam-se na informação de orientação das regiões do crânio e caudal e permitiram realizar a medida com um erro relativo próximo do referido na literatura para a variabilidade intra-operador. No entanto, apresentam, elevada dependência da segmentação realizada o que, à falta de um segmentador robusto, constitui uma importante limitação. Como conclusão mais geral retenha-se a dificuldade de encontrar um método suficientemente generalizador que permita realizar uma qualquer tarefa, seja ela de segmentação ou de deteção dos

pontos de medida, de forma independente à imagem de entrada (a SVM melhora este aspeto). Associadas a cada metodologia existirão sempre limitações, independentemente da sua natureza ou complexidade, pelo que a estratégia mais óbvia e, porventura, mais eficiente, consistirá numa implementação colaborativa que usufrua do melhor que cada método tem para oferecer. Este tipo de solução pode passar por uma implementação hierarquizada, cujo resultado não será imune à escolha do método para cada nível/fase do processo, ou paralelizada. A combinação de ambas também não deverá ser excluída.

A associação de métodos, levanta no entanto, um conjunto de questões e implicações que não são simples de responder. Que métodos selecionar? Quais os custos computacionais? Esta última é relativamente simples de aferir e pode ser determinada à partida tendo em atenção a natureza do problema e das soluções implementadas. A primeira é mais complexa e, pelo que se sabe, não tem resposta trivial. A solução acaba por resultar essencialmente da experiência e intuição de quem aborda o problema.

Face ao exposto propõe-se como trabalho futuro o estudo de metodologias que possam melhorar o desempenho dos algoritmos propostos. Seria interessante o desenvolvimento/teste de outras abordagens que permitissem resolver o problema da falta de informação morfológica fetal. A inclusão desta componente, vista a uma escala mais global, poderia ser realizada quer na fase de decisão, através da sua inclusão no processo de otimização, quer numa fase posterior através do desenvolvimento de metodologias mais robustas que a THG para encontrar a forma fetal na imagem segmentada.

Relativamente à SVM seria importante analisar o comportamento com mais imagens de treino e estender a sua utilização a outras medidas, nomeadamente à TN por ser a mais importante sob o ponto de vista do diagnóstico das anomalias fetais. A associação da SVM com métodos de contornos ativos pode representar uma boa solução para este problema e merece tratamento no futuro.

Sugere-se ainda a utilização de abordagens de redução da dimensionalidade/mapeamento não lineares. Apesar de a PCA permitir a redução da dimensão do espaço de entrada a um subespaço menor, fá-lo segundo um mecanismo linear que não permite tratar distribuições de dados com elevada não linearidade. Como tal o uso de métodos não lineares poderão melhorar a separabilidade dos dados nestas condições. Neste domínio os *autoencoders* de base neuronal têm sido usados com grande sucesso em metodologias recentes como o *Deep Learning* e poderiam ser exploradas no futuro.

Por último sugere-se o desenvolvimento de modelos de validação do grau de confiança sobre os resultados obtidos que permitam ao utilizador do sistema de medição automático ter um *score* indicativo da certeza do resultado obtido.



## BIBLIOGRAFIA

- Ahmed, M. N., Yamany, S. M., Mohamed, N., Farag, A. A., & Moriarty, T. (2002). A modified fuzzy C-means algorithm for bias field estimation and segmentation of MRI data. *IEEE Transactions on Medical Imaging*, 21(3), 193–199. <http://doi.org/10.1109/42.996338>
- Akay, M. F. (2009). Support vector machines combined with feature selection for breast cancer diagnosis. *Expert Systems with Applications*, 36(2), 3240–3247. <http://doi.org/10.1016/j.eswa.2008.01.009>
- Anzalone, A., Fusco, G., Isgrò, F., Orlandi, E., Prevete, R., Sciortino, G., et al. (2013). A system for the automatic measurement of the nuchal translucency thickness from ultrasound video stream of the foetus. *2013 IEEE 26th International Symposium on Computer-Based Medical Systems (CBMS)*, 239–244. <http://doi.org/10.1109/CBMS.2013.6627795>
- Aubert, G., & Kornprobst, P. (2008). *Mathematical Problems in Image Processing* (Vol. 147). Springer Science & Business Media. <http://doi.org/10.1007/978-0-387-44588-5>
- Azhari, H. (2010). *Basics of Biomedical Ultrasound for Engineers*. Hoboken, NJ, USA: John Wiley & Sons. <http://doi.org/10.1002/9780470561478>
- Balla-Arabé, S., Gao, X., & Bin Wang. (2013). A fast and robust level set method for image segmentation using fuzzy clustering and lattice Boltzmann method. *IEEE Transactions on Cybernetics*, 43(3), 910–920. <http://doi.org/10.1109/TSMCB.2012.2218233>
- Ballard, D. H. (1981). Generalizing the Hough transform to detect arbitrary shapes. *Pattern Recognition*, 13(2), 111–122. [http://doi.org/10.1016/0031-3203\(81\)90009-1](http://doi.org/10.1016/0031-3203(81)90009-1)
- Bengio, Y., Goodfellow, I. J., & Courville, A. (2015). *Deep Learning*. Book in preparation for MIT Press. <http://www.iro.umontreal.ca/~bengioy/dlbook>. Accessed in 2015.
- Bernardino, F., Cardoso, R., Montenegro, N., Bernardes, J., & de Sa, J. M. (1998). Semiautomated ultrasonographic measurement of fetal nuchal translucency using a computer software tool. *Ultrasound in Medicine & Biology*, 24(1), 51–54. [http://doi.org/10.1016/S0301-5629\(97\)00235-4](http://doi.org/10.1016/S0301-5629(97)00235-4)
- Bezdek, J. C. (1973). Cluster Validity with Fuzzy Sets. *Journal of Cybernetics*, 3(3), 58–73. <http://doi.org/10.1080/01969727308546047>
- Bezdek, J. C. (1975). Mathematical Models for Systematics and Taxonomy. *Proceedings of Eighth International Conference on Numerical Taxonomy*, 3, 143–166.
- Bezdek, J. C. (1981). *Pattern recognition with fuzzy objective function algorithms*. Norwell, MA, USA. Kluwer Academic Publishers

- Bezdek, J. C. (2012). *Pattern Recognition with Fuzzy Objective Function Algorithms*. Boston, MA: Springer. <http://doi.org/10.1007/978-1-4757-0450-1>
- Bezdek, J. C., Ehrlich, R., & Full, W. (1984). FCM: The fuzzy c-means clustering algorithm. *Computers & Geosciences*, 10(2-3), 191–203. [http://doi.org/10.1016/0098-3004\(84\)90020-7](http://doi.org/10.1016/0098-3004(84)90020-7)
- Blanz, V., Schölkopf, B., Bülthoff, H. H., Burges, C., Vapnik, V., & Vetter, T. (1996). Comparison of View-Based Object Recognition Algorithms Using Realistic 3D Models. *Artificial Neural Networks ICANN'96, Lecture Notes in Computer Science*, 1112, 251–256. [http://doi.org/10.1007/3-540-61510-5\\_45](http://doi.org/10.1007/3-540-61510-5_45)
- Burges, C. J. C. (1998). A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining Knowledge Discovery*, 2(2), 121–167. <http://doi.org/10.1023/A:1009715923555>
- Bushberg, J. T., Seibert, J. A., Leidholdt, E. M., & Boone, J. M. (2011). *The Essential Physics of Medical Imaging*. Lippincott Williams & Wilkins.
- Butt, K., & Lim, K. (2014). Determination of gestational age by ultrasound. *Journal of Obstetrics and Gynaecology Canada*, 36(2), 171–183.
- Cai, W., Chen, S., & Zhang, D. (2007). Fast and robust fuzzy c-means clustering algorithms incorporating local information for image segmentation. *Pattern Recognition*, 40(3), 825–838. <http://doi.org/http://dx.doi.org/10.1016/j.patcog.2006.07.011>
- Carneiro, G., Georgescu, B., Good, S., & Comaniciu, D. (2008). Detection and measurement of fetal anatomies from ultrasound images using a constrained probabilistic boosting tree. *IEEE Transactions on Medical Imaging*, 27(9), 1342–1355. <http://doi.org/10.1109/TMI.2008.928917>
- Catanzariti, E., Fusco, G., Isgrò, F., Masecchia, S., Prevete, R., & Santoro, M. (2009). A Semi-automated Method for the Measurement of the Fetal Nuchal Translucency in Ultrasound Images. *Image Analysis and Processing - ICIAP 2009, Lecture Notes in Computer Science*, 5716, 613–622. [http://doi.org/10.1007/978-3-642-04146-4\\_66](http://doi.org/10.1007/978-3-642-04146-4_66)
- Chalana, V., Kim, Y. (1997). A Methodology for Evaluation of Boundary Detection Algorithms on Medical Images. *IEEE Transactions on Medical Imaging*, 16(5), 642–652. <http://doi.org/10.1109/42.640755>
- Chalana, V., Winter, T. C., Cyr, D. R., Haynor, D. R., & Kim, Y. (1996). Automatic fetal head measurements from sonographic images. *Academic Radiology*, 3(8), 628–635. [http://doi.org/10.1016/S1076-6332\(96\)80187-5](http://doi.org/10.1016/S1076-6332(96)80187-5)
- Chan, T. F., & Vese, L. A. (2001). Active contours without edges. *IEEE Transactions on Image Processing*, 10(2), 266–277. <http://doi.org/10.1109/83.902291>
- Chattopadhyay, S., Pratihari, D. K., & De Sarkar, S. C. (2008). Developing fuzzy classifiers to predict the chance of occurrence of adult psychoses. *Knowledge-Based Systems*, 21(6), 479–497. <http://doi.org/10.1016/j.knosys.2008.03.006>



- Chen, S. C., & Zhang, D. Q. (2004). Robust image segmentation using FCM with spatial constraints based on new kernel-induced distance measure. *IEEE Transactions on Systems Man and Cybernetics Part B-Cybernetics*, 34(4), 1907–1916. <http://doi.org/10.1109/TSMCB.2004.831165>
- Chuang, K.-S., Tzeng, H.-L., Chen, S., Wu, J., & Chen, T.-J. (2006). Fuzzy c-means clustering with spatial information for image segmentation. *Computerized Medical Imaging and Graphics*, 30(1), 9–15. <http://doi.org/10.1016/j.compmedimag.2005.10.001>
- Cortes, C., & Vapnik, V. (1995). Support-Vector Networks. *Machine Learning*, 20(3), 273–297. <http://doi.org/10.1007/BF00994018>
- Courant, R., & Hilbert, D. (1953). Methods of mathematical physics - Vol.1; Vol.2. New York: Interscience Publication.
- de Oliveira, J. V., & Pedrycz, W. (2007). Advances in Fuzzy Clustering and its Applications. Chichester, UK: John Wiley & Sons. <http://doi.org/10.1002/9780470061190>
- Deng, Y., Wang, Y., Chen, P., & Yu, J. (2012). A hierarchical model for automatic nuchal translucency detection from ultrasound images. *Computers in Biology and Medicine*, 42(6), 706–713. <http://doi.org/10.1016/j.compbiomed.2012.04.002>
- Deng, Y.-H. D. Y.-H., Wang, Y.-Y. W. Y.-Y., & Chen, P. C. P. (2008). Estimating Fetal Nuchal Translucency Parameters from its Ultrasound Image. *Transactions of the IRE Professional Group on Audio*, 2643–2646. <http://doi.org/10.1109/ICBBE.2008.994>
- DGS. (2015). Direção-Geral da Saúde. Retrieved 2015, from <http://www.dgs.pt/directrizes-da-dgs/normas-e-circulares-normativas/norma-n-0232011-de-29092011-atualizada-a-21052013.aspx>
- Dhawan, A. P. (2011). Medical Image Analysis. Hoboken, NJ, USA: John Wiley & Sons. <http://doi.org/10.1002/9780470918548>
- Dhombres, F., Khoshnood, B., Bessis, R., Fries, N., Senat, M.-V., & Jouannic, J.-M. (2014). Quality of first-trimester measurement of crown-rump length. *American Journal of Obstetrics and Gynecology*, 211(6), 672–675. <http://doi.org/10.1016/j.ajog.2014.06.012>
- Dunn, J. C. (1974). A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters. *Journal of Cybernetics*, Vol. 3 (3), 32-57.
- Fox, M. D. (2010). Distance Regularized Level Set Evolution and Its Application to Image Segmentation. *Distance Regularized Level Set Evolution and Its Application to Image Segmentation*, 19(12), 3243–3254. <http://doi.org/10.1109/TIP.2010.2069690>
- Fukuyama, Y., & Sugeno, M. (1989). A new method of choosing the number of clusters for fuzzy c-means method. *Proceedings of Fifth Fuzzy Systems Symposium*, 247-250.

- Gath, I., & Gev, A. B. (1989). Unsupervised Optimal Fuzzy Clustering. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11(7), 773–780. <http://doi.org/10.1109/34.192473>
- Grobbelaar, R., & Douglas, T. S. (2007). Stereo image matching for facial feature measurement to aid in fetal alcohol syndrome screening. *Medical Engineering & Physics*, 29(4), 459–464. <http://doi.org/10.1016/j.medengphy.2006.06.005>
- Gunn, S. R. (1998). Support vector machines for classification and regression. *ISIS Technical Report*.
- Gupta, D., Anand, R. S., & Tyagi, B. (2015). A hybrid segmentation method based on Gaussian kernel fuzzy clustering and region based active contour model for ultrasound medical images. *Biomedical Signal Processing and Control*, 16, 98–112. <http://doi.org/10.1016/j.bspc.2014.09.013>
- Hanna, C. W., & Youssef, A. B. M. (1997). Automated measurements in obstetric ultrasound images. *Proceedings of International Conference on Image Processing*, vol.3, 3, 504–507. <http://doi.org/10.1109/ICIP.1997.632168>
- Hughes, M., Spring, M., & Podoleanu, A. (2010). Speckle noise reduction in optical coherence tomography of paint layers. *Applied Optics*, 49(1), 99–107. <http://doi.org/10.1364/AO.49.000099>
- Hwang, S.-H., Kim, D., Kang, T.-K., & Park, G.-T. (2007). Medical Diagnosis System of Breast Cancer Using FCM Based Parallel Neural Networks. *Advanced Intelligent Computing Theories and Applications. With Aspects of Artificial Intelligence*, 4682, 712–719. [http://doi.org/10.1007/978-3-540-74205-0\\_75](http://doi.org/10.1007/978-3-540-74205-0_75)
- Ibrahim, E.-S. H., Weiss, R. G., Stuber, M., Spooner, A. E., & Osman, N. F. (2008). Identification of different heart tissues from MRI C-SENC images using an unsupervised multi-stage fuzzy clustering technique. *Journal of Magnetic Resonance Imaging*, 28(2), 519–526. <http://doi.org/10.1002/jmri.21452>
- Jardim, S. M. G. V. B., & Figueiredo, M. A. T. (2005). Segmentation of fetal ultrasound images. *Ultrasound in Medicine & Biology*, 31(2), 243–250. <http://doi.org/10.1016/j.ultrasmedbio.2004.11.003>
- Jolliffe, I. T. (2013). Principal Component Analysis. New York, NY: Springer Science & Business Media. <http://doi.org/10.1007/978-1-4757-1904-8>
- Kane, S. A. (2009). Introduction to Physics in Modern Medicine, Second Edition. Taylor & Francis.
- Karabatak, M., & Ince, M. C. (2009). An expert system for detection of breast cancer based on association rules and neural network. *Expert Systems with Applications*, 36(2), 3465–3469. <http://doi.org/10.1016/j.eswa.2008.02.064>
- Kass, M., Witkin, A., & Terzopoulos, D. (1988). Snakes: Active contour models. *International Journal of Computer Vision*, 331, 321–331.
- Klawonn, F. (2005). Understanding and Controlling the Membership Degrees in Fuzzy Clustering, in *From Data and Information Analysis to Knowledge Engineering Proceedings of the 29th Annual Conference of the Gesellschaft für Klassifikation e.V. University of Magdeburg*, 446–453. [http://doi.org/10.1007/3-540-31314-1\\_54](http://doi.org/10.1007/3-540-31314-1_54)

- Kolapkar, S., & Wakankar, A. (2014). Automated Gestational Age Estimation for Monitoring Fetal Growth. *2014 International Conference on Advanced Communication, Control and Computing Technologies (ICACCCT)* (pp. 1104–1109). <http://doi.org/10.1109/ICACCCT.2014.7019268>
- Lee, Y.-B., Kim, M.-J., & Kim, M.-H. (2007). Robust border enhancement and detection for measurement of fetal nuchal translucency in ultrasound images. *Medical & Biological Engineering & Computing*, 45(11), 1143–1152. <http://doi.org/10.1007/s11517-007-0225-7>
- Lu, W., Tan, J., & Floyd, R. (2005). Automated fetal head detection and measurement in ultrasound images by iterative randomized Hough transform. *Ultrasound in Medicine & Biology*, 31(7), 929–936. <http://doi.org/10.1016/j.ultrasmedbio.2005.04.002>
- Ma, Y., & Guo, G. (2014). Support Vector Machines Applications. Cham: Springer Science & Business Media. <http://doi.org/10.1007/978-3-319-02300-7>
- Malladi, R., & Sethian, J. A. (1996). Level set and fast marching methods in image processing and computer vision. *3rd IEEE International Conference on Image Processing*, Vol. 1, 489–492. <http://doi.org/10.1109/ICIP.1996.559540>
- Marhaban, M. H., Kaid, R. S., & Noor, S. B. M. (2010). Automatic Estimation of Gestational Age in Ultrasound Images Based on Direct Least-Squares Fitting of Ellipse. *IEEE Transactions on Electrical and Electronic Engineering*, 5(5), 569–573. <http://doi.org/10.1002/tee.20574>
- Moratalla, J., Pintoffi, K., Minekawa, R., Lachmann, R., Wright, D., & Nicolaides, K. H. (2010). Semi-automated system for measurement of nuchal translucency thickness. *Ultrasound in Obstetrics and Gynecology*, 36(4), 412–416. <http://doi.org/10.1002/uog.7737>
- Mumford, D., & Shah, J. (1989). Optimal approximations by piecewise smooth functions and associated variational problems. *Communications on Pure and Applied Mathematics*, 42(5), 577–685. <http://doi.org/10.1002/cpa.3160420503>
- Napolitano, R., Dhami, J., Ohuma, E. O., Ioannou, C., Conde-Agudelo, A., Kennedy, S. H., et al. (2014). Pregnancy dating by fetal crown-rump length: a systematic review of charts. *BJOG: an International Journal of Obstetrics and Gynaecology*, 121(5), 556–565. <http://doi.org/10.1111/1471-0528.12478>
- Nicolaides, K. H. (2004). Nuchal translucency and other first-trimester sonographic markers of chromosomal abnormalities. *American Journal of Obstetrics and Gynecology*, 191(1), 45–67.
- Nicolaides, K. H., & DeFigueiredo, D.B. (2004). O exame ultra-sonográfico entre 11–13+6 semanas. Londres: Fetal Medicine Foundation.
- Nicolaides, K. H., Sebire, N. J., & Snijders, J. M. (2000). O exame ultra-sonográfico entre 11-14 semanas. New York: The Parthenon Publishing Group.

- Nirmala, S., & Palanisamy, V. (2009). Measurement of Nuchal Translucency Thickness for Detection of Chromosomal Abnormalities using First Trimester Ultrasound Fetal Images. *International Journal of Computer Science and Information Security*, Vol. 6, No. 3, 101-106.
- Noble, J. A., & Boukerroui, D. (2006). Ultrasound image segmentation: a survey. *IEEE Transactions on Medical Imaging*, 25(8), 987–1010. <http://doi.org/10.1109/TMI.2006.877092>
- Osher, S., & Fedkiw, R. (2003). *Level Set Methods and Dynamic Implicit Surfaces*. Springer Verlag.
- Osher, S., & Sethian, J. A. (1988). Fronts Propagating with Curvature-Dependent Speed: Algorithms Based on Hamilton-Jacobi Formulations. *Journal of Computational Physics*, 79(1), 12–49. [http://doi.org/10.1016/0021-9991\(88\)90002-2](http://doi.org/10.1016/0021-9991(88)90002-2)
- Osuna, E., Freund, R., & Girosi, F. (1997). Training Support Vector Machines: an Application to Face Detection. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 130–136. <http://doi.org/10.1109/CVPR.1997.609310>
- Özbay, Y., Ceylan, R., & Karlik, B. (2006). A fuzzy clustering neural network architecture for classification of ECG arrhythmias. *Computers in Biology and Medicine*, 36(4), 376–388. <http://doi.org/10.1016/j.compbiomed.2005.01.006>
- Pal, N. R., & Bezdek, J. C. (1995). On cluster validity for the fuzzy c-means model. *IEEE Transactions on Fuzzy Systems*, 3(3), 370–379. <http://doi.org/10.1109/91.413225>
- Park, J. H., Sofka, M., Lee, S., Kim, D., & Zhou, S. K. (2013). Automatic Nuchal Translucency Measurement from Ultrasonography. *Medical Image Computing and Computer-Assisted Intervention*, 16(Pt 3), 243–250. [http://doi.org/10.1007/978-3-642-40760-4\\_31](http://doi.org/10.1007/978-3-642-40760-4_31)
- Pathak, S. D., Chalana, V., & Kim, Y. (1997). Interactive automatic fetal head measurements from ultrasound images using multimedia computer technology. *Ultrasound in Medicine & Biology*, 23(5), 665–673.
- Pennec, X., Cachier, P., & Ayache, N. (2003). Tracking brain deformations in time sequences of 3D US images. *Pattern Recognition Letters*, 24(4-5), 801–813. [http://doi.org/10.1016/S0167-8655\(02\)00183-6](http://doi.org/10.1016/S0167-8655(02)00183-6)
- Rezaee, B. (2010). A cluster validity index for fuzzy clustering. *Fuzzy Sets and Systems*, 161(23), 3014–3025. <http://doi.org/10.1016/j.fss.2010.07.005>
- Rezaee, M. R., Lelieveldt, B. P. F., & Reiber, J. H. C. (1998). A new cluster validity index for the fuzzy c-mean. *Pattern Recognition Letters*, 19(3), 237–246. [http://doi.org/10.1016/S0167-8655\(97\)00168-2](http://doi.org/10.1016/S0167-8655(97)00168-2)
- Rodrigues, P. S. (2008). *Técnicas de segmentação e de classificação em imagens. Estudo de um caso de aplicação*, Tese de Doutorado, Guimarães: Universidade do Minho.
- Salomon, L. J., Bernard, M., Amarsy, R., Bernard, J. P., & Ville, Y. (2009). The impact of crown-rump length measurement error on combined Down syndrome screening: a simulation study. *Ultrasound in Obstetrics and Gynecology*, 33(5), 506–511. <http://doi.org/10.1002/uog.6371>

- Schmidt, M. S. (1996). Identifying speaker with support vector networks. *Proceedings of the 28th Symposium on the Interface (Interface'96)*, Sydney, Australia.
- Sethian, J. A. (1999). *Level Set Methods and Fast Marching Methods*. Cambridge University Press.
- Singh, A., Goldgof, D. B., & Terzopoulos, D. (1998). *Deformable Models in Medical Image Analysis*. Los Alamitos, California: IEEE Computer Science.
- Sonia, R. (2014). Ultrasound Image Classification for Down Syndrome During First Trimester Using Haralick Features. *International Journal of Engineering and Technology*, 6(2), 781-788.
- Souka, A. P., Krampfl, E., Bakalis, S., Heath, V., & Nicolaides, K. H. (2001). Outcome of pregnancy in chromosomally normal fetuses with increased nuchal translucency in the first trimester. *Ultrasound in Obstetrics and Gynecology*, 18(1), 9–17. <http://doi.org/10.1046/j.1469-0705.2001.00454.x>
- Suri, J. S., Setarehdan, S. K., & Singh, S. (2002). *Advanced Algorithmic Approaches to Medical Image Segmentation*. Springer Science & Business Media.
- Szilagyi, L., Benyo, Z., Szilagyi, S. M., & Adam, H. S. (2003). MR brain image segmentation using an enhanced fuzzy C-means algorithm. *Engineering in Medicine and Biology Society, Proceedings of the 25th Annual International Conference of the IEEE*, Vol. 1, 724–726 <http://doi.org/10.1109/IEMBS.2003.1279866>
- Thomas, J. G., Jeanty, P., Peters, R. A., & Parrish, E. A. (1991). Automatic measurements of fetal long bones. A feasibility study. *Journal of Ultrasound in Medicine*, 10(7), 381–385.
- Valente, R. X., Braga, A. P., & Pedrycz, W. (2013). A New Fuzzy Clustering Validity Index Based on Fuzzy Proximity Matrices. *2013 BRICS Congress on Computational Intelligence and 11th Brazilian Congress on Computational Intelligence*, 489–494. <http://doi.org/10.1109/BRICS-CCI-CBIC.2013.87>
- Vapnik, V. (1982). *Estimation of Dependences Based on Empirical Data*. New York: Springer-Verlag.
- Vapnik, V. N. (1995). *The Nature of Statistical Learning Theory*. New York, USA: Springer-Verlag New York, Inc.
- Vapnik, V. N. (1998). *Statistical Learning Theory*. Wiley-Interscience.
- Wang, J., Kong, J., Lu, Y., Qi, M., & Zhang, B. (2008). A modified FCM algorithm for MRI brain image segmentation using both local and non-local spatial constraints. *Computerized Medical Imaging and Graphics*, 32(8), 685–698. <http://doi.org/10.1016/j.compmedimag.2008.08.004>
- Wang, W., & Zhang, Y. (2007). On fuzzy cluster validity indices. *Fuzzy Sets and Systems*, 158(19), 2095–2117. <http://doi.org/10.1016/j.fss.2007.03.004>
- Watson, W. J., & Seeds, W. (2004). Diagnostic obstetric ultrasound. In *Gynecology Obstetrics*, vol. 3, Philadelphia: Lippincott Williams & Wilkins.

- Wee, L. K., Min, T. Y., Arooj, A., & Supriyanto, E. (2010). Nuchal translucency marker detection based on artificial neural network and measurement via bidirectional iteration forward propagation. *Transactions on Information Science and Applications*, 7(8), 1025–1036.
- Welsh, A. (2008). Antenatal care routine care for the healthy pregnant woman. London: Royal College of Obstetricians and Gynaecologists.
- Worzel, W. P., Yu, J., Almal, A. A., & Chinnaiyan, A. M. (2009). Applications of genetic programming in cancer research. *International Journal of Biochemistry & Cell Biology*, 41(2), 405–413. <http://doi.org/10.1016/j.biocel.2008.09.025>
- Wu, K. L., & Yang, M. S. (2005). A cluster validity index for fuzzy clustering. *Pattern Recognition Letters*, 26(9), 1275–1291. <http://doi.org/10.1016/j.patrec.2004.11.022>
- Xie, X., & Beni, G. (1991). A Validity Measure for Fuzzy Clustering. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 13(8), 841–847. <http://doi.org/10.1109/34.85677>
- Yang, M.-S., & Tsai, H.-S. (2008). A Gaussian kernel-based fuzzy c-means algorithm with a spatial bias correction. *Pattern Recognition Letters*, 29(12), 1713–1725. <http://doi.org/10.1016/j.patrec.2008.04.016>
- Yu, Jinhua, Wang, Y., & Chen, P. (2008). Fetal ultrasound image segmentation system and its use in fetal weight estimation. *Medical & Biological Engineering & Computing*, 46(12), 1227–1237. <http://doi.org/10.1007/s11517-008-0407-y>
- Zador, I. E., Salari, V., Chik, L., & Sokol, R. J. (1991). Ultrasound measurement of the fetal head: computer versus operator. *Ultrasound in Obstetrics and Gynecology*, 1(3), 208–211. <http://doi.org/10.1046/j.1469-0705.1991.01030208.x>

## ANEXO A – PROVA FCM

O *clustering* baseado no método FCM é um problema de otimização com restrições. Este tipo de problemas é resolvido com auxílio dos Multiplicadores de Lagrange por forma a transformar um problema restrito num problema sem restrições. O problema FCM consiste na minimização da função de custo:

$$J_m = \sum_{k=1}^N \sum_{j=1}^C \mu_{jk}^m \|x_k - c_j\|^2 \quad (\text{A.1})$$

onde  $N$  representa o número de pontos,  $C$  o número de grupos (*clusters*) desejado,  $\mu_{jk}$  a função pertença que traduz a crença do ponto  $x_k$  pertencer ao cluster  $j$ ,  $x_k$  um ponto do espaço de dados e  $c_j$  o centro do *cluster*  $j$ .  $m$  é um parâmetro que permite controlar a *fuzzificação*.

Um ponto  $x_k$  que possua uma distância reduzida ao centro  $c_j$ , possui um valor de  $\mu_{jk}$  elevado, enquanto que um ponto que esteja a uma distância elevada possuirá um valor baixo. Fica claro que a separação dos dados é realizada recorrendo a uma medida de distância, no caso Euclidiana.

A minimização da função de custo obedece às seguintes restrições:

$$0 \leq \mu_{jk} \leq 1, \quad \forall j, k \quad (\text{A.2})$$

$$\sum_{j=1}^C \mu_{jk} = 1, \quad \forall k \quad (\text{A.3})$$

$$0 \leq \sum_{k=1}^N \mu_{jk} \leq N, \quad \forall j \quad (\text{A.4})$$

As equações (A.2), (A.3) e (A.4) definem, respetivamente, que o valor da função pertença de um ponto a um *cluster* terá de estar no intervalo  $[0,1]$ , que a soma dos graus de pertença de um ponto a todos os *clusters* é igual a 1 (daí este método ser também chamado de probabilístico) e a soma das funções pertença do conjunto de pontos a um determinado *cluster* terá de ser inferior ao número total de pontos.

O método de Lagrange transforma o problema de minimização da função original num problema de maximização da função de Lagrange:

$$L = f(x) - \sum_{q=1}^{nq} \sum_{k=1}^N \lambda_{kq} h_{kq}(x) \quad (\text{A.5})$$

onde  $f(x)$  representa a função de custo original,  $nq$  o número de restrições,  $\lambda_{qk}$  o chamado multiplicador de Lagrange e  $h_{qk}(x)$  a restrição.

Tendo por base a Equação (A.5) a nova função de custo, para um determinado ponto  $k$  é dada por:

$$J_L = \sum_{j=1}^C \mu_{jk}^m \|x_k - c_j\|^2 - \lambda \left( \sum_{j=1}^C \mu_{jk} - 1 \right) \quad (\text{A.6})$$

onde o termo  $\sum_{j=1}^C \mu_{jk} - 1$  resulta da restrição representada na Equação (A.3).

Calculando a derivada de  $J_L$  com respeito aos parâmetros  $\mu_{jk}$  vem:

$$\frac{\partial J_L}{\partial \mu} = \sum_{j=1}^C m \mu_{jk}^{m-1} \|x_k - c_j\|^2 - \lambda \quad (\text{A.7})$$

Igualando a zero:

$$m \mu_{jk}^{m-1} \|x_k - c_j\|^2 - \lambda = 0 \quad (\text{A.8})$$

e resolvendo em ordem a  $\mu_{jk}$ :

$$\mu_{jk} = \left( \frac{\lambda}{m \|x_k - c_j\|^2} \right)^{m-1} \quad (\text{A.9})$$

$$\mu_{jk} = \left( \frac{\lambda}{m} \right)^{m-1} \frac{1}{m \|x_k - c_j\|^{\frac{2}{m-1}}} \quad (\text{A.10})$$

mas como  $\sum_{i=1}^C \mu_{ik} = 1$  então:

$$\left( \frac{\lambda}{m} \right)^{m-1} \sum_{i=1}^C \|x_k - c_i\|^{\frac{-2}{m-1}} = 1 \quad (\text{A.11})$$

pelo que:



$$\left(\frac{\lambda}{m}\right)^{m-1} = \frac{1}{\sum_{i=1}^C \frac{1}{\frac{1}{\|x_k - c_i\|^{\frac{2}{m-1}}}}} \quad (\text{A.12})$$

que substituindo em (A.10):

$$\mu_{jk} = \sum_{i=1}^C \left( \frac{\|x_k - c_j\|}{\|x_k - c_i\|} \right)^{\frac{-2}{m-1}} \quad (\text{A.13})$$

Desta forma a função pertença de cada ponto depende do inverso da norma quadrática do ponto ao centro em questão, normalizado pela soma das distâncias quadráticas do mesmo ponto aos restantes *clusters*.

Para a dedução da expressão dos centros deve-se calcular derivada de  $J_L$  com respeito aos parâmetros  $c_j$ , pelo que:

$$\frac{\partial J_L}{\partial c} = \sum_{k=1}^N -2\mu_{jk}^m (x_k - c_j) \quad (\text{A.14})$$

que igualando a zero e calculando em ordem a  $c_j$ :

$$-2 \sum_{k=1}^N \mu_{jk}^m x_k - \mu_{jk}^m c_j = 0 \quad (\text{A.15})$$

$$\sum_{k=1}^N \mu_{jk}^m x_k - c_j \sum_{k=1}^N \mu_{jk}^m = 0 \quad (\text{A.16})$$

$$c_j = \frac{\sum_{k=1}^N \mu_{jk}^m x_k}{\sum_{k=1}^N \mu_{jk}^m} \quad (\text{A.17})$$

A Equação (A.17) traduz o cálculo iterativo dos protótipos que minimizam a distância de cada ponto ao respetivo *cluster*.



## ANEXO B – DISCRETIZAÇÃO DA IMPLEMENTAÇÃO DO MÉTODO CHAN-VESE

A discretização do método Chan-Vese para o cálculo da evolução do LS consiste na implementação de diferenças finitas dadas por:

$$\Delta_-^x \phi_{i,j} = \phi_{i,j} - \phi_{i-1,j} \quad (B.1)$$

$$\Delta_+^x \phi_{i,j} = \phi_{i+1,j} - \phi_{i,j} \quad (B.2)$$

$$\Delta_-^y \phi_{i,j} = \phi_{i,j} - \phi_{i,j-1} \quad (B.3)$$

$$\Delta_+^y \phi_{i,j} = \phi_{i,j+1} - \phi_{i,j} \quad (B.4)$$

onde  $\phi$  representa a Função Level Set definida na mesma grelha da imagem, pelo que  $(x_i, y_j) = (ih, jh)$ , com  $h$  a representar o intervalo espacial.

A discretização da Equação (4.19) é dada por:

$$\frac{\phi_{i,j}^{n+1} - \phi_{i,j}^n}{\Delta t} = \delta_h(\phi_{i,j}^n) + \left[ \begin{aligned} & \frac{\mu}{h^2} \Delta_-^x \left( \frac{\Delta_+^x \phi_{i,j}^{n+1}}{\sqrt{(\Delta_+^x \phi_{i,j}^n)^2/h^2 + (\phi_{i,j+1}^n - \phi_{i,j-1}^n)^2/(2h)^2}} \right) + \\ & \frac{\mu}{h^2} \Delta_-^y \left( \frac{\Delta_+^y \phi_{i,j}^{n+1}}{\sqrt{(\Delta_+^y \phi_{i,j}^n)^2/h^2 + (\phi_{i+1,j}^n - \phi_{i-1,j}^n)^2/(2h)^2}} \right) - \\ & -\nu - \lambda_1 (u_{0,i,j} - c_1(\phi^n))^2 + \lambda_2 (u_{0,i,j} - c_2(\phi^n))^2 \end{aligned} \right] \quad (B.5)$$

com  $\Delta t$  a representar o intervalo de tempo e  $\lambda_1$ ,  $\lambda_2$ ,  $\mu$  e  $\nu$  os pesos das componentes que constituem a função de custo definida pela Equação (4.16) e  $c_1$  e  $c_2$  dadas por:

$$c_1(\phi) = \frac{\int_{\Omega} u_0(x,y) H(\phi(x,y)) dx dy}{\int_{\Omega} H(\phi(x,y)) dx dy} \quad (B.6)$$

$$c_2(\phi) = \frac{\int_{\Omega} u_0(x,y) (1 - H(\phi(x,y))) dx dy}{\int_{\Omega} (1 - H(\phi(x,y))) dx dy} \quad (B.7)$$

onde  $H$  representa a função Heaviside regularizada e calculada por:

$$H(z) = \frac{1}{2} \left( 1 + \frac{2}{\pi} \arctan \left( \frac{z}{\varepsilon} \right) \right) \quad (\text{B.8})$$

com  $\varepsilon \rightarrow 0$ . A função  $\delta(\phi)$  da Equação (B.5) é a derivada de  $H$ .

## ANEXO C – CONDIÇÕES DE MERCER

As condições de Mercer devem ser cumpridas para que um determinado *kernel*,  $K(x,y)$ , possa ser usado como mapeador.

Uma função real  $K(x,y)$  diz-se que cumpre as condições de Mercer se para todas as funções quadraticamente integráveis  $g(x)$  ( $\int (g(x))^2 dx < \infty$ ) se tem:

$$\iint K(x,y)g(x)g(y)dx dy \geq 0 \quad (C.1)$$

O não cumprimento desta condição implica, geralmente, que possam existir dados para os quais a Hessiana é indefinida e para os quais o problema de programação quadrática não terá solução.

